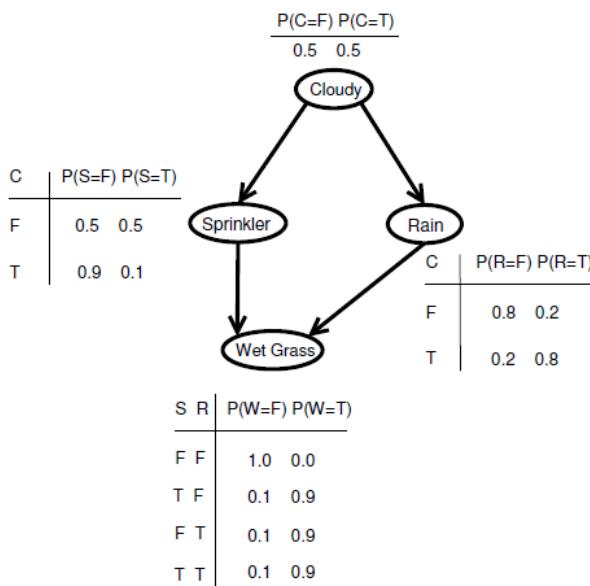


# یادگیری ساختاری شبکه‌های بیزی

## یک رهیافت مبتنی بر آتاماتاهای یادگیر

محمد رضا ملاخیلی مبیدی و محمد رضا مبیدی



شکل ۱: نمونه‌ای از یک شبکه بیزی.

نشان‌دهنده ارتباط وابستگی مستقیم بین این متغیرها است [۲]. برای هر متغیر  $x_i \in \bar{V}$  یک خانواده از توزیع‌های شرطی  $p(x_i | Pa(x_i))$  موسوم به پارامتر داریم که  $Pa(x_i)$  مجموعه والدهای متغیر  $x_i$  را نشان می‌دهد. توزیع تجمعی روی  $\bar{V}$  را می‌توان از طریق این توزیع‌های شرطی به دست آورد [۳]

$$p(x_1, x_2, \dots, x_n) = \prod_{i=1}^n p(x_i | Pa(x_i)) \quad (1)$$

که (۱) نشان‌دهنده تجزیه توزیع توان است. روابط وابستگی / استقلالی که این تجزیه را ممکن می‌کنند به شکل گرافیکی در ساختار شبکه بیزی کد می‌شوند. به بیان دیگر، وجود یا عدم وجود ارتباطات مستقیم میان جفت‌های متغیرها، وابستگی یا عدم وابستگی مستقیم بین متغیرها را نشان می‌دهند. نمونه‌ای از یک شبکه بیزی و روابط استقلال شرطی میان متغیرها را در شکل ۱ مشاهده می‌کنید.

مسئله یادگیری یک شبکه بیزی را می‌توان به این صورت توصیف کرد: یک مجموعه آموزشی  $\{x_1, x_2, \dots, x_n\} \subset \bar{V}$  از نمونه‌هایی از  $\bar{V}$  داده شده است. شبکه بیزی BN را به گونه‌ای بیایید که بهترین تطبیق با داده‌های  $D$  را داشته باشد. این مسئله در رده مسائل NP-Hard رده‌بندی می‌شود [۴] و لذا باید از روش‌های مکافهای<sup>۳</sup> آن را حل کرد.

رهیافت معمول برای حل این مسئله استفاده از یکتابع امتیازدهی  $f$  است که بر اساس داده‌های آموزشی می‌تواند هر یک از شبکه‌های ممکن را ارزیابی و امتیازدهی کند. بر اساس این امتیاز، جست و جو برای یافتن

چکیده: یکی از مسایل جالب در هوش مصنوعی ساخت شبکه بیزی بر اساس نمونه‌هایی از داده‌ها است؛ یعنی فرض کنید یک شبکه بیزی  $N$  روی مجموعه متغیرهای  $\bar{V}$  مفروض است. هدف، ساخت یک شبکه بیزی - استخراج مجموعه‌ای از روابط علت/معلوی- میان مجموعه متغیرها بر اساس نمونه‌هایی که از  $N$  استخراج شده و بدون در اختیار داشتن  $N$  است. از این مسئله در متون با عنوان یادگیری ساختاری شبکه بیزی یاد می‌شود. یکی از روش‌های مهم در یادگیری ساختاری شبکه‌های بیزی با استفاده از داده‌های نمونه، استفاده از معیارهای مبتنی بر امتیاز برای ارزیابی میزان برازنده‌گی یک ساختار بیزی مفروض با داده‌های نمونه و جست و جو در میان ساختارهای ممکن است. جست و جو برای یافتن یک ساختار مناسب برای شبکه بیزی که بیشترین سازگاری را با نمونه‌ها داشته باشد غالباً از طریق جست و جو در فضای ساختارها با استفاده از تکنیک‌های جست و جوی استاندارد یا الهام‌گرفته از طبیعت نظیر تپه‌نوردی حریصانه، الگوریتم‌های ژنتیک، شبیه‌سازی حرارتی یا الگوریتم تبرید، بهینه‌سازی کلونی مورچه‌ها و نظایر آن صورت می‌گیرد.

در این مقاله یک روش جدید مبتنی بر آتاماتای یادگیر برای یادگیری ساختاری شبکه بیزی ارائه شده است. در این روش آتاماتای یادگیر به عنوان یک ابزار جستجوی تصادفی مورد استفاده قرار می‌گیرد. از ویژگی‌های روش جدید پیشنهادی جستجوی همزمان در فضای جایگشت‌های ممکن از متغیرها (فضای ترتیب متغیرها) و فضای ساختارها (فضای DAGها) است. ضمن بررسی ریاضی الگوریتم پیشنهادی، روش جدید روی تعدادی از شبکه‌های نمونه مورد آزمایش قرار گرفته است.

**کلیدواژه:** یادگیری ساختار شبکه بیزی، آتاماتای یادگیر.

### ۱- مقدمه

یک شبکه بیزی - یا آن گونه که در ادبیات این حوزه مصطلح است، شبکه باور<sup>۱</sup> یا شبکه علی<sup>۲</sup> ابزاری برای بازنمایی دانش است که امکان مدیریت مؤثر ارتباطات وابستگی / استقلالی / استقلال را میان متغیرهای تصادفی تشکیل دهنده دامنه مسئله‌ای که مدل کردن آن مدد نظر است فراهم می‌کند [۱]. این نمایش از دو مؤلفه تشکیل شده است: ساختار و پارامترها. ساختار شبکه بیزی یک گراف جهت دار و فاقد دور  $G = (\bar{V}, E)$  است که در آن  $\{x_1, x_2, \dots, x_n\} \subset \bar{V}$  مجموعه گره‌هایی است که متغیرهای سیستم را نشان می‌دهند و  $E \subseteq (\bar{V} \times \bar{V})$  یک مجموعه از یال‌ها و

این مقاله در تاریخ ۱۰ اسفند ماه ۱۳۹۲ دریافت و در تاریخ ۱۲ آذر ماه ۱۳۹۳ بازنگری شد.

محمد رضا ملاخیلی مبیدی، دانشگاه آزاد اسلامی، واحد میبد، گروه کامپیوتر، مبیدی، (email: mollakhalili@mabodaiu.ac.ir)

محمد رضا مبیدی، آزمایشگاه محاسبات نرم، دانشکده مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه صنعتی امیرکبیر، تهران، (email: mmeybodi@aut.ac.ir).

1. Belief Network

2. Causal Network

طبیعت [۱۱] مجددًا تلاش‌هایی برای حل این مسئله صورت گرفته است [۱۲].

نگاه دیگری که به روش‌های پیشنهادی برای حل مسئله یادگیری ساختاری می‌توان داشت، به نحوه بررسی تناسب و برآزنده‌ی ساختارهای گوناگون برمی‌گردد [۱]. در گروهی از این روش‌ها از آزمون‌های استقلال شرطی [۱۹] و در گروهی دیگر از روش‌های مبتنی بر امتیازدهی [۲۰] تا [۸] برای تعیین میزان برآزنده‌ی یک ساختار با داده‌های نمونه استفاده شده و در برخی نیز ترکیبی از هر دو مورد استفاده قرار گرفته است [۲۰]. از منظری دیگر می‌توان الگوریتم‌های مورد استفاده برای یادگیری ساختار یک شبکه بیزی را به دو گروه تقسیم کرد. گروهی که در فضای DAG‌های مختلف ممکن به جست و جو می‌پردازند [۹]، [۱۸] و [۲۱] و گروهی دیگر که در میان ترتیب‌های مختلف متغیرها به جستجوی بهترین ساختار می‌پردازند [۲۲] تا [۲۴]. گروه دوم الگوریتم‌ها در مقایسه با گروه اول فضای جست و جوی محدود شده‌تری دارند و بنابراین اگر یک ترتیب کلی از متغیرها مفروض باشد، پیداکردن بهترین ساختار به مسئله انتخاب بهترین والدها برای هر گره تقاضی می‌یابد. اما اگر ترتیب شناخته شده نباشد می‌توانیم به جای جست و جو روی DAG‌های مختلف، روی مرتب‌سازی‌های مختلف جست و جو را انجام دهیم.

برخی از نویسندهان نشان داده‌اند که جست و جو در فضای جایگشت‌های متغیرها از جست و جو در فضای ساختارها مناسب‌تر و الگوریتم به دست آمده کارآمدتر و دقیق‌تر است [۲۴] و [۲۵].

### ۱-۲ جست و جو در فضای جایگشت‌ها

یک شبکه بیزی  $G = (\vec{V}, E)$  را می‌توان با بردارهای  $G = (\vec{G}_1, \vec{G}_2, \dots, \vec{G}_n)$  از مجموعه والدهای هر یک از رؤوس متناظر با مجموعه متغیرهای  $\{x_1, x_2, \dots, x_n\} = \vec{V}$  توصیف کرد. به عبارت دیگر  $\vec{G}_i$  زیرمجموعه‌ای از  $\vec{V}$  است که یال‌هایی از آنها به سمت  $x_i$  وجود دارد. به عنوان مثال شبکه  $G = (\{1, 2, 3\}, \{1, 3\}, \{1, 2\})$  با  $Ord = \{4, 1, 3, 2\}$  متناظر با یک DAG با مجموعه یال‌های  $\{3 \rightarrow 1, 3 \rightarrow 2, 2 \rightarrow 1, 1 \rightarrow 2\}$  است که این شبکه را در شکل ۲ مشاهده می‌کنید. علاوه بر این از مفهوم ترتیب متغیرها استفاده می‌کنیم. مجموعه متغیرهای  $V$  با یک ترتیب مشخص مثلاً  $\{4, 1, 3, 2\}$  را در نظر بگیرید.  $i$ . امین عنصر در یک ترتیب را با  $Ord_i$  نمایش می‌دهیم. مثلاً در ترتیب مشخص شده  $Ord = \{1, 2, 3, 4\}$  است.

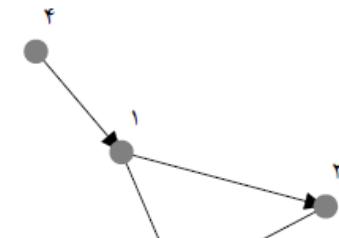
**تعریف ۱ (سازگاری شبکه بیزی با یک ترتیب):** یک شبکه بیزی

$$\forall i, \vec{G}_i \subseteq \bigcup_{j=1}^{i-1} Ord_j \quad (4)$$

بر اساس این تعریف زمانی که تمام والدهای یک گره در ترتیب  $Ord$  قبل از آن گره قرار گیرند شبکه را با ترتیب مفروض سازگار گویند. به عنوان مثال شبکه  $G = (\{1, 2, 3\}, \{1, 3\}, \{1, 2\})$  در شکل ۲ با ترتیب  $\{4, 1, 3, 2\}$  سازگار است.

در هر DAG حداقل یک گره فاقد یال خروجی وجود دارد، گره‌ای که والد هیچ گره دیگری نیست و این گره‌ها Sink شبکه گویند. وجود Sink‌ها ناشی از قدر دور بودن DAG است. هر مسیر جهت‌دار در DAG بایستی طول محدودی داشته باشد و پایان یک مسیر با حداقل طول به یک Sink ختم می‌شود.

در [۲۶] یک رهیافت مبتنی بر جست و جوی بهترین ترتیب برای شبکه‌های بیزی با تعداد متغیرهای کم پیشنهاد شده است. این روش،



شکل ۲: نمونه‌ای از یک DAG سازگار با ترتیب  $\{4, 1, 3, 2\}$  و متناظر با شبکه  $G = (\{1, 2, 3\}, \{1, 3\}, \{1, 2\})$ .

بهترین شبکه صورت می‌گیرد. معیارهای امتیازدهی متعددی اعم از بیزی و غیر بیزی در متون پیشنهاد شده و قابل استفاده است [۵] تا [۸]. مهم‌ترین ویژگی مورد انتظار از یک شاخص  $f$  تجزیه‌پذیری<sup>۱</sup> آن در زیراطی وجود داده‌های کامل است، یعنی تابع امتیازدهی می‌تواند به صورت زیر تجزیه شود

$$f(G : D) = \sum_{i=1}^n f(x_i, Pa(x_i)) : N_{x_i, Pa(x_i)} \quad (2)$$

که  $N_{x_i, Pa(x_i)}$  آماره متغیر  $x_i$  و  $Pa(x_i)$  در داده‌های  $D$  است. به عبارت دیگر تعداد نمونه‌هایی از  $D$  که با  $x_i$  و  $Pa(x_i)$  مطابقت دارند. تجزیه‌پذیری این معیار از نقطه نظر الگوریتم‌های جست و جو و یادگیری فوق العاده با اهمیت است. یک پروسه جست و جو محلی که یک یال را در هر گام تغییر می‌دهد (مثالاً یالی را به مجموعه یال‌های یک شبکه موجود می‌افزاید یا آن را حذف می‌کند) بایستی بتواند به گونه‌ای مؤثر میزان تغییرات پدیدآمده ناشی از این تغییر را ارزیابی کند که تنها در صورت تجزیه‌پذیری تابع امتیازدهی امکان‌پذیر است. ادامه این مقاله به این صورت سازمان‌دهی شده است: در بخش ۲ به بررسی مفصل پیشینه شده موضوع پرداخته‌ایم. بخش ۳ به توضیح کوتاهی درباره آناماتای یادگیر اختصاص داده شده است. در بخش ۴ روش جدید پیشنهادی تشریح شده و بخش ۵ به بررسی تجربی الگوریتم پیشنهادی اختصاص یافته است. در بخش ۶ به بررسی تجربی همگرایی روش جدید پیشنهادی پرداخته‌ایم و در نهایت بخش ۷ به نتیجه‌گیری و پیشنهادهایی برای کارهای آتی اختصاص یافته است.

## ۲- بررسی کارهای صورت گرفته

ثابت شده است که  $(n, r)$  تعداد ساختارهای مختلف برای یک شبکه

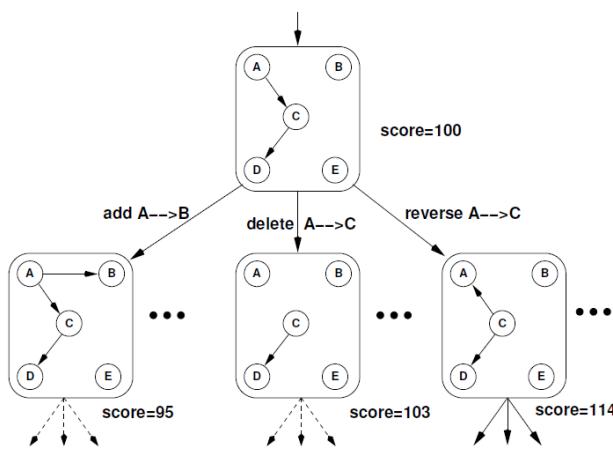
بیزی با  $n$  گره از طریق رابطه بازگشتی (۳) قابل محاسبه است [۹]

$$r(n) = \sum_{k=1}^n (-1)^{k+1} \frac{n!}{(n-k)! k!} r(n-k) = n^{O(n)} \quad (3)$$

بدیهی است جست و جو برای یافتن جواب در چنین فضای جواب بزرگی ناممکن است. بنابراین بایستی از روش‌های مکاشفه‌ای برای جست و جو یافتن یک بهترین جواب یا نزدیک‌ترین جواب بهره گرفت.

الگوریتم‌های متعددی که برای حل مسئله یادگیری ساختاری شبکه بیزی پیشنهاد شده را می‌توان از منظرهای گوناگون دسته‌بندی کرد.

از نظر زمانی بخش عمده‌ای از تلاش‌های صورت گرفته برای حل این مسئله به دو دهه پیش برمی‌گردد که با دیدگاه آماری به حل مسئله نگاه شده است [۶]، [۸] و [۱۰]. با پیداکردن روش‌های بهینه‌سازی الگوگرفته از



شکل ۴: فرایند جست و جوی مورد استفاده توسط الگوریتم جست و جوی تپه‌نوردی (صفحه ۱۹، شکل ۲ و ۳). [۲۸]

امتیازات هر گراف را در این همسایگی محاسبه می‌کند. سپس گرافی در همسایگی را که بیشینه امتیاز را کسب کند به عنوان گراف بعدی برای جست و جوی مرحله بعد انتخاب می‌کند.

در شبکه‌های بیزی مجموعه همسایگی را می‌توان مجموعه گراف‌هایی تعریف کرد که با گراف فعلی در کم یا زیادشدن یک یال یا تعییر جهت یک یال تفاوت دارند (شکل ۴). ما در بخش شبیه‌سازی‌ها از نسخه‌هایی از این الگوریتم به نامهای HC<sup>۱</sup> و GS۲ استفاده خواهیم کرد [۲۷] که شمای کلی الگوریتم در شکل ۳ نشان داده شده است.

### ۴-۲ الگوریتم B

الگوریتم B یک روش ساخت شبکه بیزی به شیوه مکائشفه‌ای حریصانه است [۹] که این روش با یک DAG خالی شروع می‌کند (یک شبکه فاقد یال). در هر گام یالی که بتواند بیشترین افزایش را در معیار امتیاز  $f$  ایجاد کند و موجب ایجاد حلقه در گراف نشود را به ساختار می‌افزاید. این الگوریتم تا زمانی که افزودن یک یال معتبر موجب افزایش در امتیاز نشود ادامه می‌یابد. این الگوریتم در زمرة الگوریتم‌هایی است که فضای ساختارها را برای یافتن ساختار بهینه جست و جو می‌کنند.

در این الگوریتم  $A[i, j]$  یک ماتریس مجاورت است که مقادیر مختلف  $f(x_i, Pa(x_i)) - f(x_i, Pa(x_j))$  را ذخیره می‌کند. این مقدار، پیبود به دست آمده ناشی از افزودن یال جهت‌دار  $x_j \rightarrow x_i$  را نشان می‌دهد. یال‌هایی که افزودن آنها در گراف باعث پیدایش سیکل چهت‌دار می‌شود با انتساب مقدار  $-\infty$  به  $A[i, j]$  مشخص می‌شوند. در هر گام بعد از افزودن یال معتبر  $x_i \rightarrow x_j$  الگوریتم، یال‌هایی که افزودن آنها منع است را از لیست یال‌ها حذف می‌کند و سپس با توجه به این که  $f(x_i, Pa(x_i))$  تغییر کرده است، مقدار جدید  $A[i, k]$  را برای تمامی یال‌های معتبر  $x_i \rightarrow x_k$  محاسبه می‌کند. پیچیدگی این به روز رسانی ( $O(n^3)$ ) است. شبه کد این روش در شکل ۵ نشان داده شده است. در [۹] ترکیبی از الگوریتم B و روش بهینه‌سازی کلونی مورچه‌ها برای انجام جست و جو در فضای ساختارهای شبکه بیزی ارائه شده است. در الگوریتم پیشنهادی مسئله به شکل DAG هایی با  $n$  گره مدل شده است. حالت  $G_h$  یک DAG با گره‌های  $\bar{V} \subseteq \bar{x}_i$  و دقیقاً  $h$  یال است. مورچه به شکل تزایدی جواب را با شروع از یک گراف خالی  $G$  می‌سازد. این کار با افزودن یال  $x_i \rightarrow x_j$  به حالت فعلی  $G_h$  به دست می‌آید.

```

ورودی: مجموعه داده‌های D
خروجی: DAG متناظر با شبکه بیزی B

E ← φ ;
T ← ProbabilityTables(E, D) ;
B ← (u, E, T) ;
Score ← -∞ ;
repeat
    maxScore ← Score ;
    foreach attribute parir (X, Y)
        foreach E' ⊂ {E ∪ {X → Y}, E - {X → Y}} ,
            E - {X → Y} ∪ {Y → X} do
            T' ← ProbabilityTables(E', D)
            B' ← (u, E', T') ;
            newScore ← Score(B', D) ;
            if newScore > Score
                B ← B' ;
                Score ← newScore ;
            end if
        end for
    end for
until (Score ≤ maxScore)

```

شکل ۳: الگوریتم جست و جوی تپه‌نوردی .Hill Climbing

ورودی: مجموعه داده‌های  $D$  و  $n$ : تعداد متغیرها  
خروجی: ماتریس مجاورت DAG متناظر با شبکه بیزی در قالب ماتریس مجاورت  $A_{n \times n}$

```

repeat
    Select two indexes  $(i, j)$  such that  $(i, j) = \arg \max_{i, j} A[i, j]$  ;
    if  $A[i, j] > 0$ 
         $Pa(x_i) = Pa(x_i) \cup \{x_j\}$  ;
        end If
         $A[i, j] = -\infty$  ;
        forall  $x_a \in Ancestors(x_j) \cup \{x_j\}$  and
         $x_b \in Descendants(x_j) \cup \{x_j\}$ 
             $A[a, b] = -\infty$  ;
        end for
        for  $k \leftarrow 1:n$ 
            if  $A[i, j] > -\infty$ 
                 $A[i, k] = f(x_i, Pa(x_i) \cup \{x_k\}) - f(x_i, Pa(x_j))$  ;
            end if
        end for
    until

```

شکل ۵: الگوریتم B

جست و جو را در میان تمام ترتیب‌های ممکن و تمام مجموعه والدهای ممکن برای یک متغیر انجام می‌دهد.

### ۲-۲ جست و جو در فضای ساختارها

رهیافت اصلی که برای حل مسئله یافتن ساختار شبکه بیزی بر اساس داده‌ها وجود دارد، جست و جو در فضای گراف‌هایی چهت‌دار فاقد دور (DAG) ممکن میان متغیرها است. با توجه به بزرگی چنین فضایی از جواب‌ها، هیوریستیک‌هایی برای بهینه‌کردن فرایند جست و جو لازم است. در ادامه به برخی از تلاش‌هایی که در این زمینه صورت گرفته است اشاره خواهیم کرد.

### ۳-۲ جست و جو حریصانه

جست و جو حریصانه مشهورترین هیوریستیک بهینه‌سازی است که با یک گراف اولیه شروع می‌کند. بر اساس یک همسایگی تعریف شده

**ورودی:**  $D$  مجموعه نمونه‌ها،  $n$ : تعداد متغیرها،  $u$  حداکثر تعداد والدھای یک گره و  $Ord$  یک ترتیب از متغیرها

**خروجی:** ماتریس مجاورت DAG متناظر با شبکه بیزی در قالب بردار Parents که لیست والدھای هر گره را مشخص می‌کند.

```
for  $i \leftarrow 1:n$ 
   $\pi_i \leftarrow \phi$ ;
   $\pi_i$  والدھای گره  $i$  را نشان می‌دهد)
```

مطابق با (۶)

$OKToProceed \leftarrow true$ ;

while  $OKToProceed$  and  $|\pi_i| < u$

Let  $z$  be the node in  $Pred(x_i) - \pi_i$  that maximizes  $f_{K2}(i, \pi_i \cup \{z\})$ ;

$$z = \arg \max_{z \in Pred(x_i) - \pi_i} f_{K2}(x_i, \pi_i \cup \{z\})$$

$$P_{new} = f_{K2}(x_i, \pi_i \cup \{z\})$$

if  $P_{new} > P_{old}$

$$P_{old} \leftarrow P_{new}$$

$$\pi_i \leftarrow \pi_i \cup \{z\}$$

else

$OKToProceed \leftarrow false$ ;

end if

end while

Parents ( $x_i$ )  $\leftarrow \pi_i$ ;

end for

شکل ۷: الگوریتم K2

که  $r_i$  تعداد مقادیر مختلف ممکن متغیر  $x_i$ ،  $q_i$  تعداد پیکربندی‌های (نمونه‌های) مختلف برای متغیرها در  $(x_i, Pa(x_i), N_{ijk})$  تعداد نمونه‌ها در  $D$  که متغیر  $x_i$  در آن  $k$  مقدار را دارد و  $Pa(x_i)$  در زامین پیکربندی‌اش قرار گرفته و  $N_{ij} = \sum_{k=1}^{r+1} N_{ijk}$  است.

فرض کنید  $P(G)$  یک توزیع یکنواخت داشته باشد. با محاسبه  $\log(P(G, D))$  به جای  $P(G, D)$  داریم

$$f_{K\gamma}(G, D) = \sum_{i=1}^n f_{K\gamma}(x_i, Pa(x_i); N_{x_i, Pa(x_i)}) \quad (6)$$

که در آن

$$f_{K\gamma}(x_i, Pa(x_i); N_{x_i, Pa(x_i)}) = \sum_{j=1}^{q_i} \left( \log \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} + \sum_{k=1}^{r_i} \log(N_{ijk}!) \right) \quad (7)$$

شبکه K2 را در الگوریتم شکل ۷ مشاهده می‌کنید.

## ۶-۲ جست و جوی حریصانه در فضای هم‌ارز مارکوف

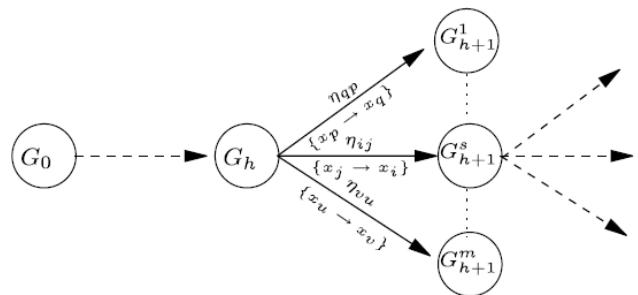
کارهای جدیدتری که در حوزه یادگیری ساختار شبکه بیزی از طریق جست و جو در فضای ساختارها صورت گرفته است، علاقه‌مندی به جست و جو در فضای هم‌ارز مارکوف را نشان می‌دهند.

**تعریف ۲:** دو DAG را هم‌ارز گوییم اگر مجموعه وابستگی / استقلال شرطی یکسانی داشته باشند. به عنوان مثال اگر  $X$  به شرط  $Y$  از  $Z$  مستقل باشد  $(X \perp Z | Y)$  در این صورت

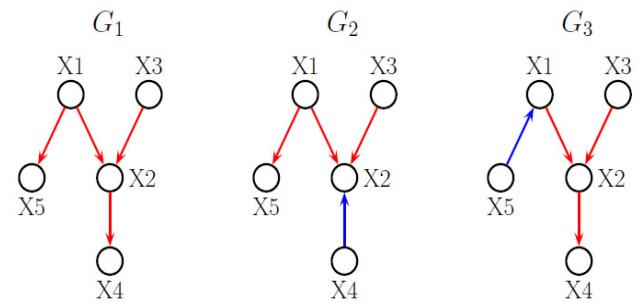
$$P(X, Y, Z) = P(X)P(Y|X)P(Z|Y) = \\ P(X|Y)P(Y)P(Z|Y) = P(X|B)P(Y|Z)P(Z)$$

در شکل ۸ سه نمونه DAG مشاهده می‌کنید که دو تای آنها با یکدیگر هم‌ارز هستند.

در شکل ۹ مشاهده می‌کنید که می‌توان با حذف جهت برخی یال‌ها را به صورتی بدون ابهام به شکل غیر جهت‌دار نشان داد.



شکل ۶: نسخه تصادفی الگوریتم B بر اساس بهینه‌سازی کلونی مورچه [۹].



شکل ۸: DAG‌های G1 و G3 هم‌ارز مارکوفی هستند اما با G2 هم‌ارز نیستند [۲۹] (صفحه ۹۱۵ شکل ۶).

یعنی  $\{x_j \rightarrow x_i\} \subseteq G_h \cup \{x_j \rightarrow x_i\}$ . جواب نهایی حالت  $G_h$  است که در آن مورچه فاز ساخت را متوقف می‌کند. هیوریستیک انتخاب شده در راستای افزودن یالی است که بیشترین افزایش را در معیار  $f$  ایجاد می‌کند و بنابراین

$$\eta_{ij} = f(x_i, Pa(x_i) \cup \{x_j\}) - f(x_i, Pa(x_i)) \quad (5)$$

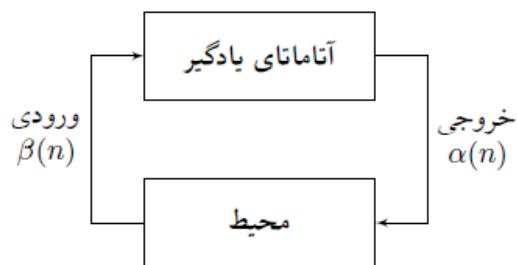
انتخاب می‌شود. فرمون‌ها با ماتریس  $\tau$  مدل می‌شوند که  $\tau_{ij}$  سطح فرومون موجود روی یال از  $j$  به  $i$  را ذخیره می‌کند. اگر  $\tau_{ij}$  سطح فرومون یال  $x_j \rightarrow x_i$  و  $G^+$  بهترین گراف یافته شده باشد مقدار فرومون بر اساس رابطه  $\tau_{ij} \leftarrow (1 - \rho)\tau_{ij} + \rho\Delta\tau_{ij}$  و در آن  $\Delta\tau_{ij} = 1/f(G^+, D)$  است اگر  $x_j \rightarrow x_i \notin G^+$  و در آن  $\Delta\tau_{ij} = \tau_{ij}$  است اگر  $x_j \rightarrow x_i \in G^+$  باشد (شکل ۶ را ملاحظه کنید).

کمان بعدی که بایستی به گراف  $G$  اضافه شود به شیوه‌ای مشابه با الگوریتم B انتخاب می‌شود با این تفاوت که تصمیم‌گیری به شکل تصادفی انجام می‌گیرد و یال با بیشترین  $[\eta_{ij}]^\beta$  انتخاب شده و به ساختار شبکه اضافه می‌شود. در [۲۴] از الگوریتم‌های ژنتیک به عنوان ابزاری برای تولید جایگشت‌ها و جست و جو در ساختارهای شبکه استفاده شده است.

## ۵-۲ الگوریتم K2

ایده اصلی الگوریتم K2 بیشینه‌کردن احتمال ساختار بر اساس داده‌های موجود است. الگوریتم K2 احتملاً یکی از بهترین الگوریتم‌هایی است که تاکنون برای یادگیری ساختار شبکه‌های بیزی ابداع شده است. این الگوریتم از یک معیار امتیازدهی بیزی استفاده می‌کند که توزیع احتمال توانم یک شبکه بیزی  $G$  و مجموعه نمونه داده‌های  $D$  را اندازه می‌گیرد. جزئیات مفصل این الگوریتم در [۶] ارائه شده است. این معیار با کمک رابطه زیر تعریف می‌شود

$$P(G, D) = P(G) \prod_{i=1}^n \prod_{j=a}^{q_i} \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \prod_{k=1}^{r_i} N_{ijk} !$$



شکل ۱۰: آتماتای یادگیر و محیط.

الگوریتم یادگیری یک رابطه بازگشتی است که برای انجام تغییرات و به روز رسانی در بردار احتمال اقدام‌های آتماتا در یک آتماتای یادگیر تصادفی با ساختار متغیر مورد استفاده قرار می‌گیرد. فرض کنید یک آتماتای یادگیر تصادفی ساختار متغیر در زمان  $k$  از میان مجموعه اقدام‌های یادگیر تصادفی عمل  $\alpha(k)$  را انتخاب کرده باشد. همچنین فرض کنید بردار احتمال انتخاب اقدام‌های آتماتا را با  $p(k)$  نمایش داده‌ایم. اگر  $a$  و  $b$  پارامترهایی باشند که به ترتیب میزان افزایش یا کاهش احتمالات اقدام‌ها را مشخص می‌کنند و  $r$  تعداد اقدام‌های قابل انجام توسط آتماتای یادگیر باشد، بردار  $p(k)$  توسط الگوریتم یادگیری خطی ارائه شده در روابط زیر به روز رسانی می‌شود. مقدار  $a$  را پارامتر پاداش و  $b$  را پارامتر جریمه می‌نامند

$$p_j(k+1) = \begin{cases} ((1-a)p_j(k) + a), & j = i \\ ((1-a)p_j(k)), & \forall j \neq i \end{cases} \quad (9)$$

$$p_j(k+1) = \begin{cases} ((1-b)p_j(k)), & j = i \\ ((1-b)p_j(k) + \frac{b}{r-1}), & \forall j \neq i \end{cases} \quad (10)$$

رابطه (۹) زمانی مورد استفاده قرار می‌گیرد که عمل  $\alpha_i(k)$  منجر به دریافت پاداش از محیط شده باشد و (۱۰) زمانی مورد استفاده قرار می‌گیرد که این عمل به دریافت جریمه از محیط منجر شود. در (۹) و (۱۰) اگر  $a=b$  باشد روابط یادگیری خطی را که الگوریتم یادگیری می‌گیرد باشد آن را  $L_{R-P}$  و اگر  $b=0$  باشد آن را  $L_{R-I}$  می‌نامند.

### ۱-۳ آتماتای یادگیر با مجموعه اقدام‌های متغیر

یک آتماتای یادگیر با مجموعه اقدام متغیر، آتماتایی است که در آن تعداد اقدام‌های موجود هر آتماتا در طول زمان تغییر می‌کند [۳۴]. فرض کنید مجموعه اقدام‌های آتماتا را با  $\{\alpha_1, \alpha_2, \dots, \alpha_r\}$  و مجموعه اقدام‌های قابل انجام توسط آتماتا در زمان  $n$  را با  $A(k) \subseteq \alpha$  نشان دهیم

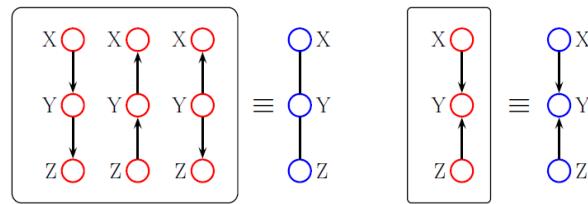
$$A(k) \in \{A_1, A_2, \dots, A_m\}, \quad m = 2^{n-1} \quad (11)$$

انتخاب زیرمجموعه  $A(k)$  از میان مجموعه اقدام‌های قابل انجام توسط آتماتا، غالباً توسط شرایط بیرونی تحمیل می‌شود. می‌توان این گونه فرض کرد که این زیرمجموعه از اقدام‌های آتماتا را که از این به بعد مجموعه اقدام‌های فعل آتماتا نامیده می‌شود، توسط یک عامل بیرونی و با توزیع احتمال

$$\psi_i(k) = \{\psi_1(k), \psi_2(k), \dots, \psi_m(k)\} \quad (12)$$

انتخاب شود. اگر تعریف کنیم

$$\hat{p}_i(k) = \text{Prob}[\alpha(k) = \alpha_i | A(k)], \quad \alpha_i \in A(k) \quad (13)$$



شکل ۹: نمایش DAG‌های همارز مارکوف به شکل PDAG [۲۹] (صفحه ۹۱۶) و شکل ۲۶. ع [۲۶].

**تعريف ۳:** یک کمان را معکوس‌پذیر گویند اگر معکوس‌کردن آن منجر به ایجاد گرافی همارز با گراف اولیه شود. فضای PDAG‌ها یا گراف‌های پایه به عنوان مجموعه تمام گراف‌های فاقد دور جزئی جهت‌دار تعریف می‌شود که تنها دارای یال‌های فاقد جهت و کمان‌های (یال‌های جهت‌دار) معکوس‌پذیر است.

**تعريف ۴:** یک معیار امتیازدهی را همارز گویند اگر روی DAG‌های همارز مقادیر یکسانی تولید کند.

نویسنده‌گان در [۳۰] نشان داده‌اند که احتمال همگراشدن جست و جو در این فضای امتیازدهی همارز نسبت به جست و جو در فضای DAG بیشتر است. این مفهوم توسعه [۳۱] و [۳۲] در روش‌های جست و جوی ساختاری پیشنهاد شده است. نویسنده در [۳۳] یک روش جست و جوی همارزی حربصانه (GES) پیشنهاد داده که از CPDAG‌ها برای نمایش کلاس‌های همارزی مارکوف استفاده کرده است. این روش در دو مرحله عمل می‌کند: مرحله‌ی اول با یک گراف خالی شروع می‌شود و افزودن کمان‌ها به آن آغاز می‌شود. افزودن کمان‌ها تا زمانی که موجب بهبود امتیاز شود ادامه پیدا می‌کند. در مرحله دوم سعی می‌کند کمان‌های نامرتب را حذف کند.

### ۳- آتماتای یادگیر

آتماتای یادگیر تصادفی یک واحد تصمیم‌گیرنده تطبیقی است که فرایند یادگیری در آن از طریق تعاملش با محیط صورت می‌گیرد. آتماتای یادگیر، مجموعه‌ای از اقدام‌های قابل انجام دارد و این اقدام‌ها به تصادف و بر اساس یک بردار توزیع احتمال، انتخاب شده و به عنوان ورودی به محیط اعمال می‌شوند. محیط، اقدام انجام‌شده را به کمک یک سیگنال تقویتی بازخوردی مورد ارزیابی قرار می‌دهد. آتماتای یادگیر بر اساس سیگنال بازخوردی حاصل، بردار توزیع احتمال انتخاب اقدام‌ها را به روز رسانی می‌کند. هدف آتماتا، پیدا کردن اقدام بهینه در میان مجموعه اقدام‌های قابل انجام است، اقدامی که بیشترین پاداش را از محیط دریافت کند.

ارتباط آتماتای تصادفی با محیط در شکل ۱۰ نشان داده شده است. از این مجموعه به همراه الگوریتم یادگیری تحت عنوان آتماتای یادگیر تصادفی نام برده می‌شود. به این ترتیب آتماتای یادگیر تصادفی را می‌توان با چهارتایی (۸) تعریف کرد

$$SLA \equiv \{\alpha, \beta, p, T, c\} \quad (8)$$

که در این رابطه  $\alpha \equiv \{\alpha_1, \alpha_2, \dots, \alpha_r\}$  مجموعه اقدام‌های آتماتا/مجموعه ورودی‌های محیط و  $\beta \equiv \{\beta_1, \beta_2, \dots, \beta_m\}$  مجموعه ورودی‌های آتماتا/مجموعه خروجی‌های محیط را نشان می‌دهد.  $T \equiv \{p_1, p_2, \dots, p_r\}$  بردار احتمال اقدام‌های آتماتا،  $p \equiv \phi \rightarrow \alpha$  مجموعه احتمالات جریمه و الگوریتم یادگیری و  $c \equiv \{c_1, c_2, \dots, c_r\}$  مجموعه احتمالات جریمه و معرف محیط است.

این قواعد تابعی از سطح فعالیت فعلی هر آتماتا و سطح فعالیت آتماتاهای مجاور است و بسته به مسئله‌ای که eDLA برای حل آن به کار گرفته می‌شود، می‌تواند متغیر باشد.

$S = (s_1, s_2, \dots, s_n)$  وضعیت آغازین سیستم نامیده می‌شود  
 $F = \{S^F \mid S^F = (s_1^F, s_2^F, \dots, s_n^F)\}$  مجموعه شرایط پایانی است.  
 مجموعه  $F$  شرایطی را بر حسب سطح فعالیت آتماتاهای مشخص می‌کند که در صورت تحقق حداقل یکی از آنها سیستم به وضعیت پایانی منتقل می‌شود.  $F$  حداقل یک عضو بدیهی دارد که در آن سطح فعالیت تمام آتماتاهای Off است.

یکتابع خاص است که بر اساس سطح فعلی فعالیت آتماتاهای و مسئله‌ای که eDLA برای حل آن طراحی شده است، آتماتایی را از میان مجموعه آتماتاهای موجود در eDLA انتخاب می‌کند.  $C$  را تابع آتش<sup>۱</sup> می‌نامیم.

هر آتماتای یادگیر در eDLA متناسب با درجه‌اش در گراف ارتباطی (در حالتی که گراف ارتباطی  $G$  فاقد جهت باشد) و یا درجه خروجی اش در گراف ارتباطی (در حالتی که گراف ارتباطی  $G$  جهت‌دار باشد) اقدام برای انجام‌دادن دارد.

نحوه انجام کار eDLA به این صورت است که از وضعیت  $S$  آغاز کرده و بر اساس مجموعه قواعد  $P$  نسبت به تغییر سطح فعلی بودن آتماتاهای اقدام می‌کند. تغییر سطح فعلی بودن آتماتاهای تا زمان حل کامل مسئله ادامه پیدا می‌کند. در هر زمان آتماتایی که در سطح فعالیت Fire قرار دارد، اقدامی را انتخاب کرده و آن را به محیط اعمال می‌کند. ضمن این که بر اساس قواعد ارتباطی، مجموعه‌ای از آتماتاهای مجاور با آتماتای Fire که در پایین ترین سطح فعلی بودن (Passive) قرار دارند، ارتقای سطح می‌بیند (به سطح Active). هر آتماتا پس از Fire شدن و انجام اقدام به وضعیت Off تغییر وضعیت می‌دهد. انتخاب آتماتای Fire از میان مجموعه آتماتاهای Active صورت می‌گیرد و غالباً به صورت تصادفی انجام می‌شود.

از eDLA تا کنون برای حل برخی مسایل استفاده شده است. نویسنده در [۳۵] مسئله یادگیری پارامتری شبکه‌های بیزی به کمک آتماتای یادگیر توزیع شده توسعه‌یافته مورد بررسی قرار گرفته است. در [۳۸] روشی مبتنی بر آتماتای یادگیر برای حل مسئله بهینه‌سازی جایگشت ارائه شده است. در [۳۹] از روش پیشنهادی در [۳۸] برای حل مسئله درخت پوشای کمینه تصادفی استفاده شده است. در [۴۰] نویسنده از eDLA برای نمونه‌گیری در شبکه‌های اجتماعی استفاده کرده است. در [۴۱] ساختار eDLA برای حل مسایل یافتن زیرگراف بهینه در گراف‌های تصادفی به صورت عام مورد بررسی و عملکرد آن به صورت دقیق مورد ارزیابی قرار گرفته است.

#### ۴- الگوریتم پیشنهادی

الگوریتم پیشنهادی که در این بخش ارائه می‌شود به جای جست و جو در فضای DAGها به جست و جو در فضای جایگشت‌ها پرداخته و از روش امیازدهی K2 برای ارزیابی جایگشت ایجادشده در هر مرحله استفاده می‌کند. همان گونه که قبلًا مذکور شدیم، فضای جایگشت‌ها K2 نسبت به فضای DAGها محدودتر است. علاوه بر این انتخاب معیار K2 در این مقاله به دلیل کاهش سربار محاسباتی از طریق ذخیره کردن نتایج جزئی میانی (Cahce کردن) و کاهش سربار محاسباتی روش پیشنهادی

(احتمال انتخاب عمل از میان مجموعه اقدام‌های فعال، به شرط آن که مجموعه اقدام‌های فعال آتماتا برابر با  $A(k)$  در این صورت باشد)

$$\hat{p}_i(k) = \frac{p_i(k)}{K(k)} \quad (14)$$

در (۱۴)  $K(k)$  مجموع احتمالات تمام اقدام‌های فعال (اقدام‌های عضو  $A(k)$  است و داریم

$$K(k) = \sum_{\alpha_i \in A(k)} p_i(k) \quad (15)$$

که در آن

$$p_i(k) = \text{Prob}[\alpha(k) = \alpha_i] \quad (16)$$

احتمال انتخاب اقدام  $\alpha_i$  در میان مجموعه تمام اقدام‌های آتماتا (اعم از این که فعال باشد یا نباشد) است. بدین ترتیب نحوه انتخاب اقدام توسط آتماتا یا مجموعه اقدام متغیر بدین صورت است که فرض کنید آتماتا مجموعه اقدام‌های فعال  $A(k)$  را داشته باشد. ضربی نرمال کننده  $K(k) = \sum_{\alpha_i \in A(k)} p_i(k)$  برای این مجموعه از اقدام‌های فعال محاسبه شده و بردار احتمال انتخاب اقدام‌های آتماتا مطابق با رابطه بالا نرمال‌سازی می‌شود (به گونه‌ای که مجموع احتمال اقدام‌های فعال همچنان ۱ باشد). پس از این آتماتا بر اساس بردار جدید  $\hat{p}_i(k)$  یکی از اقدام‌های (فعال) خود را انتخاب کرده و به محیط اعمال می‌کند. در مرحله به روز رسانی نیز بردار  $(k)$   $\hat{p}_i$  مطابق با الگوریتم یادگیری مورد استفاده توسط آتماتا به روز رسانی می‌شود و سپس با استفاده مجدد از رابطه بالا بردار  $\hat{p}_i(k) \cdot K(k) = p_i(k)$  به دست می‌آید.

نشان داده شده در صورتی که الگوریتم یادگیری مورد استفاده  $L_{R-I}$  باشد، این روش ویژگی‌های absolute expediency و  $\epsilon$ -optimality را دارد [۳۴].

#### ۲-۳ آتماتای یادگیر توزیع شده توسعه یافته

آتماتای یادگیر توزیع شده توسعه یافته شبکه‌ای است از آتماتاهای یادگیر مرتبط با هم که تحت نظارت مجموعه‌ای از قواعد ارتباطی که ناظر بر ترتیب و نحوه فعالیت آنهاست برای حل یک مسئله خاص با یکدیگر همکاری دارند [۳۵] تا [۳۷]. در آتماتای یادگیر توزیع شده توسعه یافته، هر آتماتا دارای یک سطح فعلی بودن است و زمان و نحوه تغییر سطح فعالیت آتماتاهای به تبعیت از شرایط مسئله، تغییر می‌کند. در آتماتای یادگیر توزیع شده توسعه یافته در هر زمان تنها یک آتماتا در سطحی قرار می‌گیرد که قادر به انجام اقدام و اعمال آن بر محیط است. به صورت فرمال می‌توان یک آتماتای یادگیر توزیع شده توسعه یافته را به صورت  $eDLA = \{A, E, S, P, S', F, C\}$  تعریف کرد که در آن  $A = \{1, 2, \dots, n\}$  مجموعه‌ای از آتماتاهای یادگیر است،  $E \subseteq A \times A$  مجموعه ارتباطات سلسله مرتبی میان اعضاء  $G = (A, E)$  بوده و گراف ارتباطی نامیده می‌شود.

$S = \{s_1, s_2, \dots, s_n\}$  مجموعه‌ای از مقادیر موسوم به سطح فعالیت است که سطح فعلی بودن هر آتماتایی متعلق به  $A$  را مشخص می‌کند. هر یک از  $s_i$  ها می‌توانند یکی از مقادیر Active، Passive، Fire و Off باشند که آنها را به ترتیب با Pa، Ac و Fi نمایش می‌دهیم. با این تفاوت که اگر آتماتا به سطح فعالیت off برسد، دیگر هرگز تغییر وضعیت نمی‌دهد اما در حالت Passive امکان تغییر وضعیت وجود دارد.  $P$  مجموعه‌ای محدود از قواعد حاکم بر سطح فعالیت آتماتاهای است.

وضعیت Active قرار می‌گیرند. آتاماتاهای بعده ترتیب از ریشه Fire شده و با انجام اقدام، آتاماتای بعدی که بایستی Fire شود را معین می‌کنند. آتاماتاهای از نوع تصادفی با تعداد اقدام متغیر هستند [۳۴]. با انجام یک اقدام توسط هر آتاما، سایر آتاماتاهایی که در وضعیت Active قرار دارند مجموعه اقدام‌های خود را به گونه‌ای تغییر می‌دهند که موجب ایجاد حلقه در جواب نهایی نشود. این کار با بلاک کردن اقدامی که موجب پیدایش حلقه خواهد شد صورت می‌گیرد.

**محاسبه امتیاز جایگشت:** با استفاده از جایگشت تعیین شده در مرحله قبل و داده‌ها نمونه موجود یک DAG سازگار با جایگشت بر اساس الگوریتم K2 ایجاد و امتیاز آن بر اساس (۶) و (۷) محاسبه می‌شود. eDLA از این مقدار برای تعیین پاداش یا جریمه اقدام‌های صورت گرفته توسط آتاماتاهای استفاده می‌کند. این کار با مقایسه مقدار امتیاز با یک مقدار آستانه صورت می‌گیرد. مقدار آستانه بیشینه مقدار امتیاز DAG‌های قبلی را نشان می‌دهد.

**ارزیابی اقدام انجام شده توسط eDLA:** بر اساس مقایسه انجام شده در مرحله قبل کلیه آتاماتاهای eDLA جریمه یا پاداش داده می‌شوند. اگر امتیاز جایگشت ایجاد شده از مقدار آستانه بیشتر باشد، کلیه آتاماتاهای پاداش داده می‌شوند و گرنه جریمه می‌شوند. الگوریتم جریمه یا پاداش می‌تواند یکی از الگوریتم‌های یادگیری خطی مورد بحث در بخش قبلی باشد.

به روز رسانی مقدار آستانه مقایسه و آماده‌سازی eDLA برای اجرای بعدی: مقدار آستانه به روز رسانی می‌شود. کلیه آتاماتاهای دوباره به وضعیت Active بر می‌گردند و تمامی اقدام‌های بلاک شده در مراحل قبل به وضعیت قابل انجام بر می‌گردند. eDLA برای اجرای بعدی آماده می‌شود. چنان که ملاحظه می‌شود در این الگوریتم از ساختار eDLA برای هدایت جایگشت‌ها به سمت بهترین جایگشت که بتواند معیار K2 را بیشینه کند استفاده می‌کنیم. شیوه‌کد روش جدید پیشنهادی در الگوریتم ۱۱ ارائه شده است. نمونه‌ای از اجرا را نیز در شکل ۱۲ مشاهده می‌کنید

## ۵- بررسی ریاضی روش پیشنهادی

در این قسمت به بررسی درستی عملکرد الگوریتم پیشنهادی در یافتن جایگشت بهینه‌ای که منجر به یک DAG سازگار با داده‌های نمونه با بیشینه امتیاز گردد می‌پردازیم. برای این منظور فرض کنید  $\delta_i$  یک جایگشت باشد و  $d_i$  احتمال آن را نشان دهد که ساختار DAG القایی توسط این جایگشت بر اساس الگوریتم K2 بیشینه امتیاز را کسب کرده و توسط محیط پاداش داده شود.  $c_i = 1 - d_i$  احتمال بهینه‌بودن ساختار القایی حاصل از جایگشت ایجاد شده توسط الگوریتم ۴ را نشان می‌دهد. ساختار کلی اثبات به این صورت است: در مرحله اول نشان می‌دهیم که احتمال انتخاب جایگشت بهینه (حاصل ضرب احتمال انتخاب اقدام‌ها متناظر با عناصر جایگشت و تشکیل دهنده مسیر همیلتونی در گراف eDLA) برای مقادیر به اندازه کافی بزرگ از تکرار الگوریتم یک زیرمارتبینگل است. در مرحله دوم کران‌های برای این احتمال برقرار کرده و نشان می‌دهیم با انتخاب مقدار مناسب برای پارامتر نرخ یادگیری در الگوریتم  $L_{R-1}$  توسط هر یک از آتاماتاهای در ساختار eDLA می‌توان این کران‌ها را به اندازه دلخواه به مقدار ۱ نزدیک کرد. روش استفاده شده در این بخش همان است که در [۴۱] مورد استفاده قرار گرفته است.

لم ۱: اگر  $c_i(k)$  و  $d_i(k)$  احتمالات مربوط به جریمه و تنبیه‌شدن جایگشت  $\sigma_i$  حاصل شده در  $k$  امین تکرار را نشان دهند و  $q(k)$  بر اساس الگوریتم پیشنهادی ارائه شده تغییر کند، در این صورت امید ریاضی

وروودی:  $D$ : مجموعه نمونه‌ها،  $n$ : تعداد متغیرها،  $u$ : حداکثر تعداد والدهای یک گره، آستانه‌های  $P_{TH}$  و  $K$

خروجی: ماتریس مجاورت DAG متناظر با شبکه بیزی در قالب بردار Parents که لیست والدهای هر گره را مشخص می‌کند.

Construct  $G = (V, V \times V)$  with  $V = \{0, 1, 2, \dots, n\}$  ;

Construct an eDLA from graph  $G$  ;

$k \leftarrow 0$ ,  $\Pi \leftarrow \phi$ ,  $TH_k \leftarrow -\infty$  ;

**repeat**

$P \leftarrow \phi$ ;  $A \leftarrow V$ ;  $F \leftarrow \phi$ ;  $O \leftarrow \phi$ ;

Let  $u$  denotes the position in permutation and initially set to 1;

Select  $u = \{0\} \in A$ ;

$F \leftarrow F \cup u$ ;  $A \leftarrow A - F$ ;

**while**  $|\Pi| \leq n$

$e = (u, \pi(u)) = \text{selectaction}(u)$ ;

$\Pi \leftarrow \Pi \cup \pi(u)$ ;

All LA in  $A$  prunes its action-set

$O \leftarrow O \cup F$ ;  $F \leftarrow \phi$ ;  $u \leftarrow \pi(u)$ ;

$F \leftarrow F \cup u$ ;

**end while**

**if**  $|\Pi| = n$  **then**

$\text{if } K2(D, n, u, \Pi) > TH_k \text{ then}$

Reward all  $LA \in O$  ;

**else**

penalize all  $LA \in O$  ;

**end if**

$TH_k = \max(TH_k, K2(D, n, u, \Pi))$  ;

**else**

Do nothing;

**end if**

$k \leftarrow k + 1$  ;

$q_\pi = Pr(\Pi) = \prod_{\pi(u) \in \Pi} P_{\pi(u)}^u$  ;

Enable all disable actions of  $LA \in O$  ;

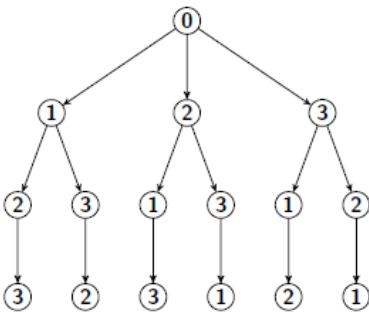
**until**  $(q_\pi > P_{TH} \vee k > K)$

شکل ۱۱: الگوریتم پیشنهادی مبتنی بر eDLA برای یادگیری ساختار شبکه بیزی.

صورت گرفته است. جست و جو در فضای جایگشت‌ها با نگاشت یک جایگشت به یک مسیر همیلتونی در یک گراف کامل صورت می‌گیرد. برای این کار از روش پیشنهادی در [۳۸] و [۴۱] استفاده شده است.

برای این منظور یک گراف کامل فاقد جهت با تعداد  $n+1$  رأس (یک رأس بیشتر از تعداد متغیرها) به عنوان گراف ارتباطی eDLA ایجاد می‌شود. هر یک از رئوس گراف ایجاد شده متناظر با یکی از متغیرها و یک رأس به عنوان ریشه است. هر یال  $e_{(i,j)}$  که رئوس  $i$  و  $j$  را در گراف به یکدیگر متصل می‌کند متناظر با اقدام  $\alpha_i^j$  از آتاما‌تای  $LA_j$  یا اقدام  $\alpha_j^i$  از آتاما‌تای  $LA_i$  است. در هر بار اجرا، eDLA از آتاما‌تای متناظر با رأس ریشه شروع کرده و بر اساس بردار احتمال انتخاب اقدام‌های آن اقدامی را انجام می‌دهد. این کار باعث تغییر وضعیت یکی از آتاما‌تاهای واقع شده در سمت دیگر یال متناظر با اقدام انجام شده به وضعیت Fire می‌شود. Fire شدن آتاما‌تاهای تا زمانی که کلیه آتاما‌تاهای Fire شوند ادامه پیدا می‌کند. با پایان این پروسه یک جایگشت (ترتیب) از متغیرها به دست می‌آید. بر اساس جایگشت ایجاد شده بهترین DAG بر اساس معیار K2 ایجاد می‌شود. مقدار K2 متناظر با جایگشت ایجاد شده به عنوان معیاری برای ارزیابی اقدام‌های صورت گرفته توسط آتاما‌تاهای استفاده می‌شود.

به صورت خلاصه می‌توان یک دور اجرای الگوریتم را متشکل از گام‌های زیر دانست:  
تشکیل یک جایگشت توسط eDLA: در ابتدای کار تمامی آتاما‌تاهای در



شکل ۱۳: درخت جایگشت‌های روی سه عنصر با شماره‌های ۱، ۲ و ۳.

جدول ۱: نحوه تعریف احتمال انتخاب هر جایگشت برای جایگشت روی سه عنصر.

جایگشت	احتمال
$\sigma_1 = (1, 2, 3)$	$q_1(k) = p_1^r(k)p_1^l(k)$
$\sigma_2 = (1, 3, 2)$	$q_2(k) = p_1^r(k)p_2^l(k)$
$\sigma_3 = (2, 1, 3)$	$q_3(k) = p_2^r(k)p_1^l(k)$
$\sigma_4 = (2, 3, 1)$	$q_4(k) = p_2^r(k)p_3^l(k)$
$\sigma_5 = (3, 1, 2)$	$q_5(k) = p_3^r(k)p_1^l(k)$
$\sigma_6 = (3, 2, 1)$	$q_6(k) = p_3^r(k)p_2^l(k)$

$$p_1^r \uparrow p_1^r \downarrow = \{p_1^r(1-a) + a\} \left\{ p_1^r(1 - \frac{a}{p_1^r(1-a)+a}) \right\} = \quad (21)$$

$$\{p_1^r(1-a) + a\} p_1^r - a p_1^r = p_1^r p_1^r (1-a) = q_1(1-a)$$

و

$$p_1^r \uparrow p_1^r \uparrow = \{p_1^r(1-a) + a\} \times \\ \left\{ p_1^r(1 - \frac{a}{p_1^r(1-a)+a}) + \frac{a}{p_1^r(1-a)+a} \right\} = \quad (22)$$

$$\{p_1^r(1-a) + a\} p_1^r - a p_1^r + a =$$

$$p_1^r p_1^r (1-a) + a = q_1(1-a) + a$$

با جایگذاری مقادیر (۲۰) تا (۲۲) در (۱۹) خواهیم داشت

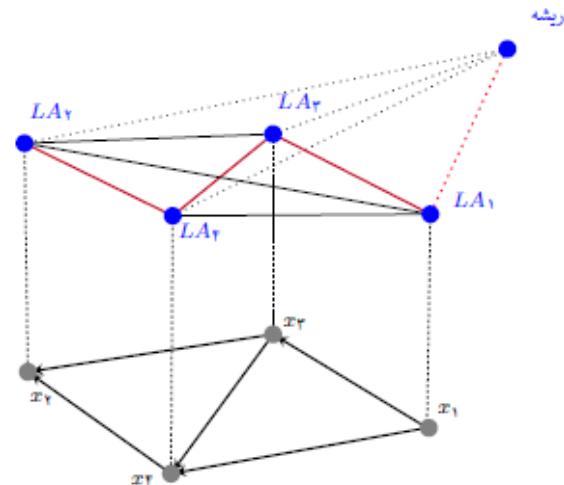
$$E[q_1(k+1)|q(k)] = \\ q_1(k)\{c_1(k)q_1(k) + d_1(k)q_1(k)(1-a)\} + \\ q_2(k)\{c_1(k)q_1(k) + d_1(k)q_1(k)(1-a)\} + \\ q_3(k)\{c_1(k)q_1(k) + d_1(k)q_1(k)(1-a)\} + \quad (23)$$

$$q_4(k)\{c_1(k)q_1(k) + d_1(k)q_1(k)(1-a) + a\} + \\ q_5(k)\{c_1(k)q_1(k) + d_1(k)q_1(k)(1-a)\} + \\ q_6(k)\{c_1(k)q_1(k) + d_1(k)q_1(k)(1-a)\}$$

با ساده‌سازی جبری (۲۳) داریم

$$E[q_1(k+1)|q(k)] = q_1(k)\{q_1(k) - ad_1(k)q_1(k)\} + \\ q_2(k)\{q_1(k) - ad_1(k)q_1(k)\} + \\ q_3(k)\{q_1(k) - ad_1(k)q_1(k)\} + \\ q_4(k)\{q_1(k) - ad_1(k)q_1(k) + ad_1(k)\} + \quad (24)$$

$$q_5(k)\{q_1(k) - ad_1(k)q_1(k)\} + \\ q_6(k)\{q_1(k) - ad_1(k)q_1(k)\} = \\ q_1(k) - \{aq_1(k) \sum_{j=1, j \neq 1}^6 q_j(k)d_j(k)\} + \\ ad_1(k)q_1(k)\{1 - q_1(k)\} = \\ q_1(k) + aq_1(k) \sum_{j=1, j \neq 1}^6 q_j(k)\{d_1(k) - d_j(k)\}$$

شکل ۱۲: تناظر بین eDLA و متغیرها و مثالی از اجرای الگوریتم پیشنهادی:  $Ord = \{1, 3, 4, 2\}$  را انتخاب می‌کند که به ترتیب  $G = \{\{\}, \{3, 4\}, \{1\}, \{3, 1\}\}$  سازگار باشد. K2 بر اساس این ترتیب DAG سازگار با امتیاز بیشینه تعیین می‌کند.شرطی  $E[q_i(k+1) - q_i(k)|q(k)]$  مطابق با (۱۷) تعریف می‌شود  
 $E[q_i(k+1) - q_i(k)|q(k)] \geq$ 

$$aq_i(k) \sum_{\substack{j=1 \\ j \neq i}}^r q_j(k)[d_i(k) - d_j(k)] \quad (17)$$

اثبات: برای اثبات، یک جایگشت روی سه عنصر را در نظر گرفته و محاسبات را انجام می‌دهیم. اگر از الگوریتم ۴ استفاده شده باشد، ۶ جایگشت ممکن برای این سه عنصر از طریق طی کردن مسیرهای مشخص شده در درخت شکل ۱۳ ساخته می‌شوند.

احتمال مناسب به هر یک از ۶ جایگشت این مثال در جدول ۱ نشان داده شده است. ضمناً فرض می‌کنیم مطابق آنچه که در [۴۲] پیشنهاد شده است نرخ یادگیری در هر یک از سطوح مطابق با (۱۸) تغییر می‌کند

$$a_{\pi_{i,j-1}}(k) = \frac{a_{\pi_{i,j-1}}(k)}{p_{\pi_{i,j-1}}(k+1)} \quad (18)$$

در (۱۸)  $a_{\pi_{i,j}}(k)$  مقدار نرخ یادگیری در زمان  $k$  برای  $j$ -امین آتاماواتی واقع در مسیر  $\pi_i$  را نشان می‌دهد [۴۳]. ما در ادامه، محاسبات را برای جایگشت  $\sigma_4$  انجام خواهیم داد

$$E[q_1(k+1)|q(k)] = \\ \sum_{\beta=1}^r \sum_{j=1}^r E[q_1(k+1)|q(k), \alpha_j, \beta] \times \\ P[\beta|\alpha_j] \times P[\alpha_j|q(k)] = \\ q_1(k)\{c_1(k)q_1(k) + d_1(k)p_1^r \downarrow p_1^r\} + \\ q_2(k)\{c_1(k)q_1(k) + d_1(k)p_1^r \downarrow p_1^r\} + \quad (19)$$

$$q_3(k)\{c_1(k)q_1(k) + d_1(k)p_1^r \uparrow p_1^r\} + \\ q_4(k)\{c_1(k)q_1(k) + d_1(k)p_1^r \uparrow p_1^r\} + \\ q_5(k)\{c_1(k)q_1(k) + d_1(k)p_1^r \downarrow p_1^r\} + \\ q_6(k)\{c_1(k)q_1(k) + d_1(k)p_1^r \downarrow p_1^r\}$$

منظور از  $\downarrow$  و  $\uparrow$  در (۱۹) به ترتیب کاهش و افزایش در مقدار احتمال یک اقدام بر اساس روش  $L_{R-1}$  است اما

$$p_1^r \downarrow p_1^r = p_1^r(1-a)p_1^r = q_1(1-a) \quad (20)$$

داده شده است [۴۴] و [۴۵] که  $U$  عملگری خطی است و توابع نامنفی را نامنفی نگه می‌دارد. یعنی

$$\text{if } g[q] \geq 0 \Rightarrow Ug[q] \geq 0 \quad \forall q \in S_r$$

نسبت به عملگر  $U$  می‌توان دو گروه از توابع موسوم به زیر- و ابر- منظم را تعریف کرد. اگر  $Ug[q] \geq g[q]$  تابع  $g[q]$  را زیرمنظم و اگر  $Ug[q] \leq g[q]$  تابع  $g[q]$  را ابرمنظم گویند.

نشان داده شده است [۴۴] که  $\Gamma_i[q]$  تنها جواب پیوسته  $UT_i[q] = \Gamma_i[q]$  با شرایط مرزی زیر است

$$\Gamma_i[e_j] = \begin{cases} 1, & i = j \\ 0, & i \neq j \end{cases} \quad (29)$$

اما حل معادله تابعی  $UT_i[q] = \Gamma_i[q]$  برای تعیین احتمال انتخاب جایگشت بهینه بر حسب احتمال اولیه توسط الگوریتم پیشنهادی، کار سختی است. برای این کار از یک کران پایین برای این تابع استفاده می‌کنیم. از گزاره قبلی می‌دانیم که احتمال انتخاب جایگشت بهینه  $q_i^* \in \{0, 1\}$  است و تعریف می‌کنیم

$$\Phi_i[x, q] = \frac{\exp \frac{-xq_i}{a} - 1}{\exp \frac{-x}{a} - 1} \quad (30)$$

که در آن  $x$  بایستی انتخاب شود. واضح است که تابع تعریف شده در (۳۰) شرایط مرزی تعریف شده در (۲۹) را ارضاء می‌کند. نشان خواهیم داد که  $\Phi_i[x, q]$  یک تابع زیرمنظم بوده و لذا قادر است که یک کران پایین برای  $\Gamma_i[q]$  تعریف کند. می‌توان نشان داد که  $\Phi_i[x, q]$  و قطبی زیرمنظم است که  $\exp(-x/a) - 1$  ابرمنظم باشد

نموداری می‌کند که  $\theta_i[x, q] = \exp(-xq_i/a) - 1$  باشد که در

نمودار  $q_i$  جایگشت بهینه  $q_i^*$  باشد که در آن  $\theta_i[x, q] = \exp(-xq_i/a) - 1$  باشد. اثبات: برای تعیین شرایطی که تحت آن شرایط، تابع  $\theta_i[x, q]$  یک تابع ابرمنظم است، از تعریف ابرمنظم و محاسبه مقدار امید ریاضی استفاده می‌کنیم. فرض کنید جایگشت  $\sigma_i$  جواب بهینه باشد، در این صورت

$$U\theta_i[x, q] = E[\exp \frac{-xq_i(k+1)}{a} | q(k) = q] \quad (31)$$

برای محاسبه مقدار امید ریاضی در (۳۱) به این ترتیب عمل می‌کنیم

$$\begin{aligned} E[\exp \frac{-xq_i(k+1)}{a} | q(k) = q] &= \\ \sum_{j=1}^r E[\exp \frac{-xq_i(k+1)}{a} | q(k) = q, \sigma_j] q_j &= \\ \sum_{j=1}^r \exp \frac{-xq_i(k+1)}{a} \times q_j \times d_j + \\ \sum_{j=1}^r \exp \frac{-xq_i(k)}{a} \times q_j \times (1-d_j) & \end{aligned} \quad (32)$$

رابطه (۳۲) در حقیقت تغییرات در احتمال انتخاب جایگشت مورد نظر  $\sigma_i$  را تحت هر نوع شرایطی و در یک گام از اجرای الگوریتم پیشنهادی مورد بررسی قرار می‌دهد. در هر گام الگوریتم پیشنهادی یک جایگشت نظری  $\sigma_r$  را انتخاب می‌کند. این جایگشت ممکن است توسط محیط با سیگنال تقویتی تنبیه جریمه شود که در این صورت با توجه به استفاده از الگوریتم

در نتیجه

$$\begin{aligned} E[q_r(k+1) | q(k)] - q_r(k) &= \\ aq_r(k) \sum_{\substack{j=1 \\ j \neq r}}^r q_j(k) \{d_r(k) - d_j(k)\} & \end{aligned} \quad (25)$$

و حکم ثابت است. ■

لم ۲: با فرض این که جایگشت  $\sigma_i$  جواب مسأله یافتن جایگشت بهینه باشد، در این صورت مقدار  $\Delta q_i(k+1) = E[q_i(k+1) - q_i(k) | q(k)]$  همواره مثبت است.

اثبات: متوسط تغییر در مقدار  $(k)$  برای جایگشت  $\sigma_i$  که از ضرب مقدار احتمال اقدام‌های متناظر با یال‌های تشکیل‌دهنده جایگشت  $\sigma_i$  تشکیل می‌شود مطابق با لم قبل برابر است با

$$\begin{aligned} \Delta q_i(k+1) &= E[q_i(k+1) - q_i(k) | q(k)] \geq \\ aq_i(k) \sum_{\substack{j=1 \\ j \neq i}}^r q_j(k) \{d_i(k) - d_j(k)\} & \end{aligned} \quad (26)$$

چون جایگشت  $\sigma_i$  بهینه است بنا بر قانون قوی اعداد بزرگ برای مقدار بزرگ  $k$  مقدار  $\{d_i(k) - d_j(k)\}$  برای هر  $j \neq i$  مثبت است و در نتیجه سمت راست (۲۶) مثبت و بنابراین برای مقدار بزرگ  $k$  طرف  $\Delta q_i(k+1) \geq 0$  راست (۲۶) مقداری مثبت است و در نتیجه ■

گزاره ۱:  $q_i^* \in \{0, 1\}$  با احتمال ۱ وجود دارد.  
لم ۲ بیان کننده آن است که  $\{q_i(k)\}$  یک زیرمارتینگل است. با استفاده از قضایای حدی مارتینگل نتیجه می‌شود که  $\lim_{k \rightarrow \infty} q_i(k) = q_i^*$  با احتمال ۱ وجود دارد. علاوه بر این اگر فرض کنیم  $q_i(k) \neq 0$  در این صورت با یک احتمال نااصر به ازای تمام مقادیر  $k$  داریم  $q_i(k+1) = q_i(k)$  و بنابراین الزاماً ■

گزاره ۱ نشان می‌دهد که احتمال انتخاب جایگشت بهینه یکی از دو مقدار ۰ یا ۱ است. به عبارت دیگر الگوریتم پیشنهادی همواره همگرا می‌شود اما احتمال این که به جوابی غیر از جواب بهینه همگرا شود وجود دارد. در این بخش نشان خواهیم داد که تحت شرایطی و با انتخاب پارامترهای مناسب برای الگوریتم یادگیری می‌توان احتمال همگرایی الگوریتم پیشنهادی به جواب بهینه را به اندازه کافی به ۱ نزدیک کرد. برای این کار از روش پیشنهادی [۴۴] که در موارد مشابه نیز مورد استفاده قرار گرفته است ([۴۳] و [۴۵]) استفاده می‌کنیم.

فرض کنید  $q^* \in V_r = \{e_1, e_2, \dots, e_r\}$  مجموعه حالت‌های جاذب فرایند  $q(k)$  باشد و  $q^* \in V_r$  حالتی را نشان دهد که  $q(k)$  به آن همگرا می‌شود. تعریف می‌کنیم

$$\Gamma_i[q] = \Pr[q^* = e_i | q(\cdot) = q] \quad (27)$$

$\Gamma_i[q]$  احتمال همگرایی الگوریتم به جایگشت  $\sigma_i$  با شروع از بردار احتمال  $q$  را نشان می‌دهد. فرض کنید

$$S_r = \{q \mid q_j \geq 0, \sum_{j=1}^r q_j = 1, j = 1, 2, \dots, r\} \quad (28)$$

فرض کنید  $C(S_r) : S_r \rightarrow \mathbb{R}$  فضای حالت تمام توابع مشتق‌پذیر  $\mathbb{R}$  پیوسته حقیقی مقدار با مشتق محدود تعریف شده روی  $S_r$  باشد که یک خط حقیقی است. اگر  $(g[q] \in C(S_r))$  باشد، الگوریتم ۴ پیشنهادی نظیر یک عملگر  $U$  با میانگین  $Ug[q] = E[g[q(k+1)] | q(k) = q]$  باشد، الگوریتم ۴ پیشنهادی عمل می‌کند که در این رابطه  $E[S_r]$  نشان‌دهنده امید ریاضی است. نشان

$$D(p_n^m) = \frac{\prod_{e(m,n) \in \sigma_i \cap \sigma_j} \{p_n^m + a(1-p_n^m)\}}{\prod_{e(m,n) \in \sigma_i \cup \sigma_j} \{p_n^m(1-a)\}} \geq 1 \quad (37)$$

با توجه به نزولی بودنتابع  $e^{-x}$  داریم

$$\exp\left\{-\frac{x}{a}q_i(1-a)\right\} \frac{\prod_{e(m,n) \in \sigma_i \cap \sigma_j} \{p_n^m + a(1-p_n^m)\}}{\prod_{e(m,n) \in \sigma_i \cup \sigma_j} \{p_n^m(1-a)\}} \leq \quad (38)$$

$$\exp\left\{-\frac{x}{a}q_i(1-a)\right\}$$

از (38) و (36) به می‌رسیم

$$U\theta_i[x, q] - \theta_i[x, q] \leq q_i d_i \times \exp\left\{-\frac{x}{a}(q_i + a(1-q_i))\right\} + \sum_{\substack{j=1 \\ j \neq i}}^r q_j d_j \times \exp\left\{-\frac{x}{a}q_j(1-a)\right\} - \theta_i[x, q] \sum_{j=1}^r q_j d_j \quad (39)$$

اما

$$\theta_i[x, q] \sum_{j=1}^r q_j d_j = q_i d_i \theta_i[x, q] + \sum_{\substack{j=1 \\ j \neq i}}^r q_j d_j \theta_i[x, q] \quad (40)$$

فلذا (41) به دست می‌آید و تعریف می‌کنیم

$$V[x] = \begin{cases} \frac{\exp(x) - 1}{x}, & x \neq 0 \\ 1, & x = 0 \end{cases} \quad (42)$$

لذا

$$U\theta_i[x, q] - \theta_i[x, q] \leq$$

$$-xq_i \theta_i[x, q]((1-q_i)d_i V[-x(1-q_i)] - \sum_{\substack{j=1 \\ j \neq i}}^r q_j d_j V[xq_j]) \quad (43)$$

(1-q\_i)d\_i V[-x(1-q\_i)] - \sum\_{\substack{j=1 \\ j \neq i}}^r q\_j d\_j V[xq\_j] \geq 0 \quad \text{شرط لازم برای}\newline \theta\_i[x, q] \text{ است، لذا برمنظم بودن}

$$(1-q_i)d_i V[-x(1-q_i)] \geq \sum_{\substack{j=1 \\ j \neq i}}^r q_j d_j V[xq_j] \quad (44)$$

یا

در (33) داریم

$$\frac{\prod_{e(m,n) \in \sigma_i \cap \sigma_j} \{p_n^m(1-a)\}}{\prod_{e(m,n) \in \sigma_i \cup \sigma_j} \{p_n^m(1-a)\}} = \frac{\prod_{e(m,n) \in \sigma_i \cap \sigma_j} \{p_n^m(1-a)\}}{\prod_{e(m,n) \in \sigma_i \cup \sigma_j} \{p_n^m(1-a)\}} = \frac{\prod_{e(m,n) \in \sigma_i} \{p_n^m(1-a)\}}{\prod_{e(m,n) \in \sigma_i \cap \sigma_j} \{p_n^m(1-a)\}} \quad (45)$$

با توجه به (31) خواهیم داشت

$$U\theta_i[x, q] = q_i d_i \times \exp\left\{-\frac{x}{a}(q_i + a(1-q_i))\right\} + \sum_{\substack{j=1 \\ j \neq i}}^r q_j d_j \exp\left\{-\frac{xq_j(1-a)}{a} D(p_n^m)\right\} + \theta_i[x, q] - \theta_i[x, q] \sum_{j=1}^r q_j \times d_j \quad (46)$$

اما روشن است که

$$\sum_{j=1}^r \exp\left\{-\frac{xq_j(k+1)}{a}\right\} q_j d_j = q_i d_i \exp\left\{-\frac{x \prod_{e(m,n) \in \sigma_i} \{p_n^m + a(1-p_n^m)\}}{a}\right\} + \sum_{\substack{j=1 \\ j \neq i}}^r q_j d_j \exp\left\{-\frac{x \prod_{e(m,n) \in \sigma_i \cap \sigma_j} \{p_n^m + a(1-p_n^m)\} \prod_{e(m,n) \in \sigma_i \cup \sigma_j} \{p_n^m(1-a)\}}{a}\right\} \quad (47)$$

$$U\theta_i[x, q] - \theta_i[x, q] \leq q_i d_i (\exp\left\{-\frac{x}{a}(q_i + a(1-q_i))\right\} - \theta_i[x, q]) + \sum_{\substack{j=1 \\ j \neq i}}^r q_j d_j (\exp\left\{-\frac{x}{a}q_j(1-a)\right\} - \theta_i[x, q]) =$$

$$\theta_i[x, q] (q_i d_i \exp\left\{-x(1-q_i)\right\} - 1 + \sum_{\substack{j=1 \\ j \neq i}}^r q_j d_j (\exp\left\{xq_j\right\} - 1)) = \quad (48)$$

$$-xq_i \theta_i[x, q] ((1-q_i)d_i \frac{\exp\left\{-x(1-q_i)\right\} - 1}{-x(1-q_i)} - \sum_{\substack{j=1 \\ j \neq i}}^r q_j \times d_j \frac{\exp\left\{xq_j\right\} - 1}{xq_j})$$

## ۶- بررسی تجربی

### ۶- آزمایش ۱: بررسی عملکرد الگوریتم

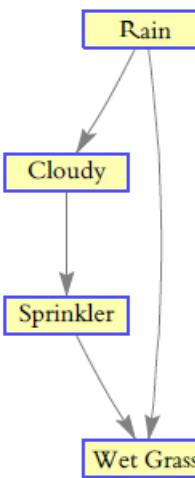
در این آزمایش برای بررسی عملکرد الگوریتم از یک شبکه بیزی ساده مطابق آنچه که در شکل ۱ مشاهده می‌کنید استفاده شده است. برای انجام آزمایش از یک نمونه ۱۰۰ تایی انتخاب شده از داده‌های تولیدشده بر اساس این شبکه استفاده شده است. شاخص  $K_2$  برای این نمونه انتخاب شده از داده‌ها در DAG اصلی،  $f_{K_2}(D, G_{original}) = -216,004$  بود. مطابق با الگوریتم ۴ کار جست و جو بهترین جایگشت انجام شده است. مبنای ارزیابی اقدام‌های آناتاما امتیاز  $K_2$  کسب شده توسط بهترین سازگار با ترتیب پیشنهادی توسط eDLA بوده است. از الگوریتم DAG سازگار با ترتیب پیشنهادی توسط  $eDLA$  بوده است. از الگوریتم یادگیری  $L_{R-1}$  با نرخ یادگیری  $0.02$  برای پاداش اقدام‌های آناتاما استفاده شده است. کار جست و جو برای یافتن بهترین ترتیب ۵۰ بار تکرار شده است. شبکه ایجادشده بر اساس این الگوریتم را در شکل ۱۴ مشاهده می‌کنید. بر اساس داده‌های نمونه، این ساختار نیز دارای امتیاز  $K_2$  با مقدار  $-216,004$  می‌باشد.

### ۶- آزمایش ۲: بررسی عملکرد مقایسه‌ای

برای انجام این آزمایش‌ها از شبکه ASIA [۴۶] و INSURANCE [۴۷] استفاده کردند. کلیه شبیه‌سازی‌ها در صورت گرفته است. فرایند انجام کار بدین صورت بوده است که از شبکه اصلی یک نمونه با تعداد مشخص گرفته شده است. بر اساس این نمونه مشخص و با استفاده از یک معیار امتیازدهی- که در آزمایش‌های این سری از معیار  $K_2$  استفاده شده است- فرایند جست و جو برای یافتن بهترین جایگشت توسط الگوریتم پیشنهادی صورت گرفته است. برای مقایسه از الگوریتم‌های  $gs_1$  و  $gs_2$  استفاده شده است. در نخستین آزمایش از شبکه ASIA استفاده شده است. این شبکه دارای ۸ گره و ۸ کمان است. از روی شبکه اصلی یک نمونه ۵۰۰۰ تایی نمونه‌گیری شده است. سپس از الگوریتم پیشنهادی و الگوریتم‌های  $hc$  و  $gs_2$  خواسته شده تا یادگیری ساختار شبکه را به کمک داده‌های نمونه انجام دهند. علاوه بر این بر اساس ترتیب اصلی گره‌ها و داده‌های نمونه و بر اساس الگوریتم  $K_2$  نیز کار یادگیری ساختار شبکه بیزی انجام شده است که ساختار حاصل را Optimal نامیده‌ایم. دلیل انجام این کار آن است که داده‌های نمونه‌گیری شده بر اساس معیار  $K_2$  نتوانند معرف ساختار اصلی باشند. کلیه مقایسه‌های بین ساختارهای حاصل از هر یک از الگوریتم‌ها با ساختار شبکه Optimal صورت گرفته است. در این آزمایش ساختار شبکه Optimal با ساختار شبکه اصلی یکسان است.

برای انجام مقایسه الگوریتم‌های مختلف با الگوریتم پیشنهادی از معیارهای زیر استفاده شده است:

- (۱) زمان اجرا: مدت زمان صرف شده توسط الگوریتم برای یافتن ساختار بر اساس داده‌های نمونه و معیار  $K_2$
- (۲) امتیاز: امتیاز کسب شده توسط شبکه ایجادشده توسط هر الگوریتم بر اساس معیار  $K_2$ . هر چقدر این امتیاز بزرگ‌تر و به امتیاز شبکه Optimal نزدیک‌تر باشد الگوریتم عملکرد بهتری دارد.
- (۳) مقایسه ساختارها: برای مقایسه بین ساختار ایجادشده توسط هر الگوریتم و ساختار شبکه Optimal از سه شاخص مرتبط با ساختار استفاده کردند. تعداد کمان‌های با طرفین و جهت درست، تعداد کمان‌های با طرفین درست و جهت نادرست و تعداد کمان‌های با طرفین و جهت نادرست.



شکل ۱۴: نتیجه اجرای الگوریتم پیشنهادی با کمک داده‌های تولیدشده از شبکه بیزی شکل ۱ و بازتولید ساختار شبکه بر اساس این داده‌ها.

$$\frac{V[-x(1-q_i)]}{V[xq_i]} \geq \frac{\sum_{j=1, j \neq i}^r q_j d_j}{(1-q_i)d_i} \quad (45)$$

در (۴۵) داریم

$$\frac{\sum_{j=1, j \neq i}^r q_j \times d_j}{(1-q_i)d_i} = \frac{\sum_{j=1, j \neq i}^r q_j \times d_j}{\sum_{j=1, j \neq i}^r q_j \times d_i} = \frac{\sum_{j=1, j \neq i}^r q_j \times \frac{d_j}{d_i}}{\sum_{j=1, j \neq i}^r q_j} \quad (46)$$

لذا

$$\min_{j \neq i} \frac{d_j}{d_i} \leq \frac{\sum_{j=1, j \neq i}^r q_j \times \frac{d_j}{d_i}}{\sum_{j=1, j \neq i}^r q_j} \leq \max_{j \neq i} \frac{d_j}{d_i} \quad (47)$$

با جایگذاری (۴۷) در (۴۵) شرط ابرمنظم بودن به (۴۸) تقلیل می‌یابد

$$\frac{V[-x(1-q_i)]}{V[xq_i]} \geq \max_{j \neq i} \frac{d_j}{d_i} \quad (48)$$

تعريف می‌کنیم  $H[x] = \ln V[x]$ . با توجه به محدب بودن  $V[x]$  می‌توان نشان داد [۴۴]

$$\frac{1}{V[x]} \leq \frac{V[-x(1-q_i)]}{V[xq_i]} \leq V[-x] \quad (49)$$

از آنجا که  $1/V[x]$  تابعی پیوسته و یکنوا کاوشی با  $V[0]$  است  $x \in \mathbb{R}^*$  و وجود دارد که برای تمام مقادیر در بازه  $[0, x^*]$  داریم  $x = x^*$   $\max_{j \neq i} (d_j/d_i) = 1/V[x^*] \leq 1/V[x]$ . با انتخاب  $x = x^*$  نابرایری (۴۵) ارضاء خواهد شد که در این صورت  $\theta_i[x, q]$  ابرمنظم خواهد بود. ■

**قضیه ۱:** فرض کنید احتمال متناظر با جایگشت بهینه  $\sigma_i$  را مرحله  $k$  نشان دهد. اگر بردار  $q(k) = [q_i(k)]_{i=1, \dots, r}$  مطابق با الگوریتم پیشنهادی تغییر کند، در این صورت  $\lim_{n \rightarrow \infty} q_i(n) = 1$ .

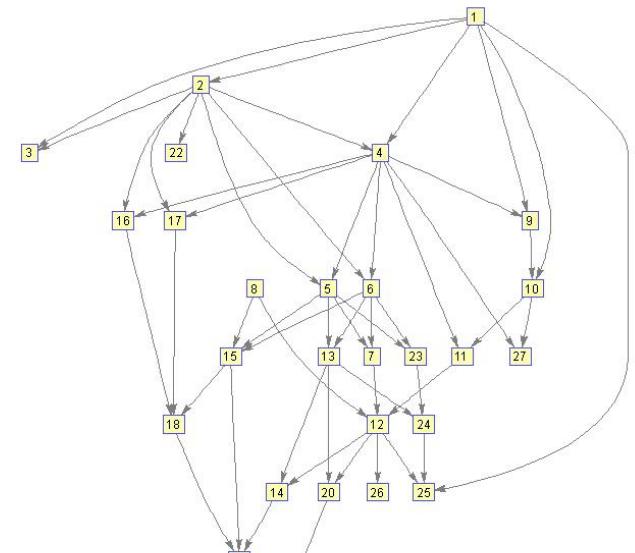
**اثبات:** با توجه به لم ۳ و تعریفتابع  $\Phi_i[x, q]$  مشاهده می‌شود که به ازای هر  $a^* > a$  مفروض، ثابت مثبت  $1 - \epsilon \leq \Phi_i[a^*, q] \leq \Phi_i[a, q] \leq 1 - \epsilon$  برقرار است. این به آن معناست که نابرایری  $\Phi_i[x, q] \leq \Gamma_i[q]$  برقرار است. این به این معناست که  $\lim_{n \rightarrow \infty} q_i(n) = 1$  و به این ترتیب اثبات قضیه ۱ کامل می‌شود. ■

جدول ۲: نتایج شاخص‌های مقایسه‌ای برای شبکه ASIA

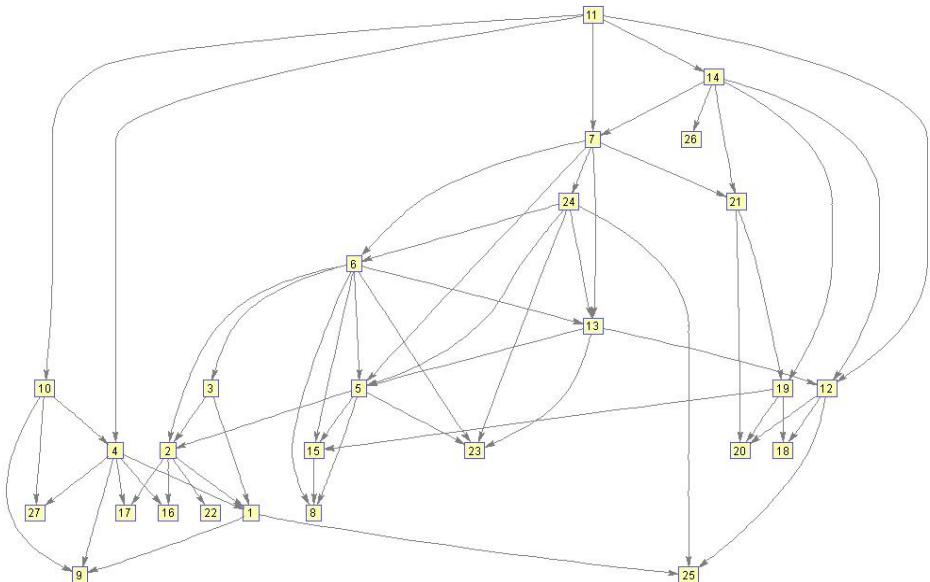
شاخص	ASIA			
	HC	GS	GS2	eDLA
Time	۲۱۷/۴۲	۲۲۱/۳۲	۲۲۹/۱۶	۱۲۷/۳۰
Score <sub>dif</sub>	-۴۰	-۴۰	-۴۰	.
n <sub>correct</sub>	۴	۴	۴	۷
n <sub>direrr</sub>	۲	۲	۲	۱
n <sub>error</sub>	۳	۳	۳	.

جدول ۳: نتایج شاخص‌های مقایسه‌ای برای شبکه INSURANCE با تعداد نمونه ۱۰۰۰۰.

شاخص	INSURANCE			
	HC	GS	GS2	eDLA
Time	۱۴۶۹۹	۱۲۹۸۶	۱۲۴۷۷	۵۰۸۲/۷
Score <sub>dif</sub>	-۲۵۹۰	-۲۵۹۰	-۲۲۱۲	-۲۱۷۰
n <sub>correct</sub>	۳۰	۳۰	۳۰	۲۰
n <sub>direrr</sub>	۱۰	۱۰	۱۰	۲۰
n <sub>error</sub>	۴	۴	۴	۱۹



شکل ۱۵: ساختار شبکه Insurance مورد استفاده.



شکل ۱۶: ساختار DAG القابی حاصل از ترتیب ایجادشده توسط الگوریتم پیشنهادی برای شبکه بیزی Insurance.

جست و جو در DAG روی شبکه بیزی Insurance (شکل ۱۵) مورد بررسی قرار گرفته است. این شبکه دارای ۲۷ گره و ۵۲ یال می‌باشد که ساختار شبکه بیزی ایجاد شده برای داده‌های نمونه‌ی این آزمایش را در شکل ۱۶ و نتایج شاخص‌های مقایسه‌ای را در جدول ۳ مشاهده می‌کنید. در شکل ۱۶ نیز ساختار شبکه بیزی پیشنهاد شده به کمک الگوریتم GS بر اساس همین داده‌های نمونه را مشاهده می‌کنید. بر اساس نتایج جدول مشاهده می‌شود که اولاً الگوریتم پیشنهادی به لحاظ زمان اجرا نسبت به الگوریتم‌های جست و جو در فضای ساختارها عملکرد بسیار بهتری دارد. علاوه بر این امتیاز ساختار القابی حاصل از جایگشت ایجادشده توسط الگوریتم پیشنهادی در مقایسه با الگوریتم‌های دیگر مورد بررسی در این مقاله بزرگ‌تر و به مقدار واقعی نزدیک‌تر است اما از نظر نظر ساختار پیشنهادی توسط الگوریتم‌ها به نظر می‌رسد ساختار پیشنهادی توسط الگوریتم مبتنی بر eDLA نسبت به سایر ساختارها پیچیده‌تر است. مشابه چنین آزمایشی روی شبکه ICU-ALARM با ۱۰۰۰۰ نمونه

نتایج مقایسه برای این آزمایش را در جدول ۲ مشاهده می‌کنید. در این جدول شاخص Time زمان اجرای الگوریتم بر حسب ثانیه و شاخص Score<sub>dif</sub> اختلاف امتیاز به دست آمده برای ساختار پیشنهادی الگوریتم از امتیاز K2 به دست آمده توسط شبکه Optimal نشان می‌دهد. امتیاز شبکه اصلی  $10^{120.8} - 1$  بوده است و n<sub>correct</sub> تعداد کمان‌های با طرفین و جهت درست در ساختار به دست آمده توسط هر الگوریتم، n<sub>direrr</sub> تعداد کمان‌های با جهت نادرست و n<sub>error</sub> تعداد کمان‌های با جهت و طرفین نادرست را نشان می‌دهند.

بر اساس نتایج این جدول مشاهده می‌شود که الگوریتم پیشنهادی که در فضای DAG‌ها به کمک شاخص K2 است نسبت به روش‌های مبتنی بر جست و جو در فضای ساختار هم از نظر زمان اجرا و هم از نظر درستی ساختار پیشنهادی عملکرد خوبی دارد. در آزمایشی مشابه عملکرد الگوریتم پیشنهادی در برابر الگوریتم‌های

جدول ۴: نتایج شاخص‌های مقایسه‌ای برای شبکه ICU-ALARM

ICU-ALARM				
شاخص	HC	GS	GS2	eDLA
Time	۴۰.۵۰۰	۴۱.۰۰۰	۴۰.۰۰۰	۱۰.۵۰۰
Score <sub>diff</sub>	-۱۱۱۰	-۱۱۱۰	-۱۱۱۰	-۷۴۰
n <sub>correct</sub>	۲۲	۲۲	۲۲	۳۳
n <sub>direrr</sub>	۱۲	۱۲	۱۲	۱۱
n <sub>error</sub>	۷	۷	۷	۲۲

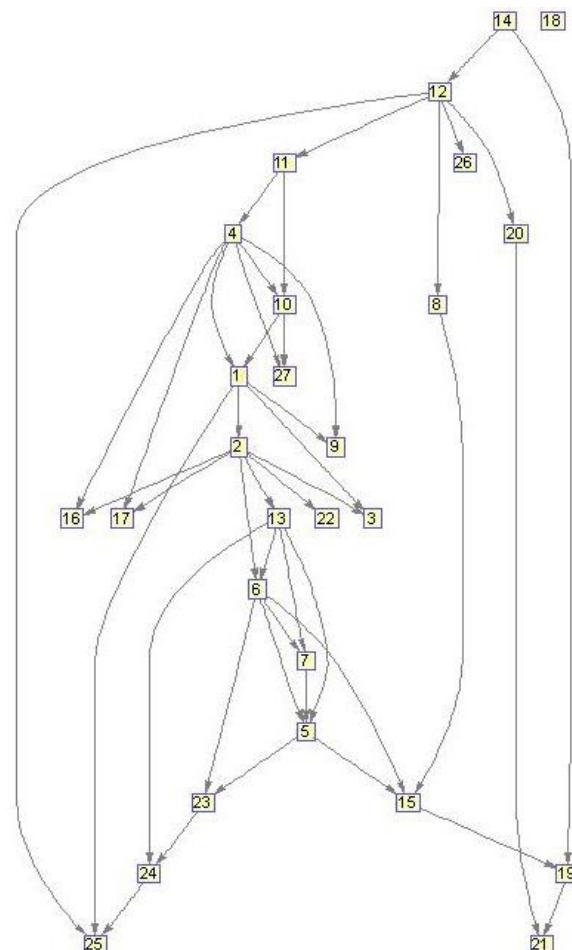
## ۷- نتیجه‌گیری

در این مقاله یک الگوریتم جدید مبتنی بر امتیاز برای یادگیری شبکه‌های بیزی مورد بررسی قرار گرفت. نوآوری این الگوریتم در استفاده از اجتماع از آتاماتاهای یادگیر به عنوان واحدهای هوشمند محاسباتی ساده برای حل این مسأله است. این اجتماع از آتاماتاهای با استفاده از بردارهای احتمال انتخاب اقدام‌های خود، الگوریتم را به سمت یافتن جایگشت مناسبی که بتواند بر اساس داده‌ها یک شبکه بیزی با بیشترین امتیاز معیار K2 را کسب کند، هدایت می‌کردد. از مزایای این روش، سادگی روش پیشنهادی به دلیل سادگی عملکرد آتاماتاهای یادگیر است. بررسی‌های تجربی روی شبکه‌های نمونه نشان‌دهنده عملکرد مناسب الگوریتم پیشنهادی در مقایسه با روش‌های جست و جوی دیگری است که در این مقاله مورد بررسی قرار گرفته‌اند.

در تحقیقات آتی، هدف ما استفاده از آتاماتاهای برای یادگیری ساختار شبکه بیزی است. برای این هدف به دنبال یافتن هیوریستیک‌هایی به منظور بهبود الگوریتم پیشنهادی فعلی و نیز استفاده از آتاماتاهای برای جست و جو در فضای ساختارها هستیم. علاوه بر این جست و جو در PDAG‌ها و استفاده از امتیازهای هم‌ارز نیز بخشی از تحقیقات آتی ما را در این راستا تشکیل می‌دهد.

## مراجع

- [1] L. de Campos and J. Puerta, "Stochastic local algorithms for learning belief networks: searching in the space of the orderings," in *Symbolic and Quantitative Approaches to Reasoning with Uncertainty*, vol. 2143, pp. 228-239, 2001.
- [2] D. Heckerman, A Tutorial on Learning with Bayesian Networks, in *Innovations in Bayesian Networks*, Berlin, Heidelberg: Springer Berlin Heidelberg, pp. 33-82, 1996.
- [3] T. Nielsen and F. Jensen, *Bayesian Networks and Decision Graphs*, 2nd Ed. Springer, 2009.
- [4] D. M. Chickering, "Learning Bayesian networks is NP-complete," in *Learning from Data*, Springer, pp. 121-130, 1996.
- [5] W. Buntine, "A guide to the literature on learning probabilistic networks from data," *IEEE Trans. Knowl. Data Eng.*, vol. 8, no. 2, pp. 195-210, Apr. 1996.
- [6] G. F. Cooper and E. Herskovits, "A Bayesian method for the induction of probabilistic networks from data," *Mach. Learn.*, vol. 9, no. 4, pp. 309-347, 1992.
- [7] D. Heckerman and D. M. Chickering, "Learning Bayesian networks: the combination of knowledge and statistical data metrics for belief networks," *Mach. Learn.*, vol. 20, no. 3, pp. 197-243, 1995.
- [8] W. Lam and F. Bacchus, "Learning Bayesian belief networks: an approach based on the MDL principle," *Comput. Intell.*, vol. 10, no. 3, pp. 269-293, Aug. 1994.
- [9] L. De Campos and J. Fernandez-Luna, "Ant colony optimization for learning Bayesian networks," *Int. J. Approx. Reason.*, vol. 31, no. 3, pp. 291-311, 2002.
- [10] D. Chickering, D. Geiger, and D. Heckerman, "Learning Bayesian networks: search methods and experimental results," in *Proc. 5th Conf. Artif. Intell. Stat.*, pp. 112-128, 1995.
- [11] ف. مریخنیات، الگوریتم‌های بهینه‌سازی الهام‌گرفته از طبیعت، نص، ۱۳۹۱.



شکل ۱۷: ساختار پیشنهادشده توسط الگوریتم جست و جوی حریصانه gs برای شبکه بیزی Insurance.

انجام شده است. از روی شبکه واقعی یک نمونه ۱۰۰۰۰۱ تایی گرفته شده است. سپس بر اساس ترتیب واقعی متغیرها ساختار شبکه Optimal با استفاده از معیار بیزی K2 محاسبه شده است. شبکه واقعی دارای ۴۶ یال بوده و شبکه Optimal دارای ۴۷ یال و امتیاز  $10^{+0.96} \times 10^{-4}$  است. سپس بر اساس داده‌های نمونه‌گیری شده از هر یک از الگوریتم‌ها خواسته شده تا کار یادگیری ساختار شبکه بیزی را انجام دهد. نتایج مقایسه‌ای را در جدول ۴ مشاهده می‌کنید.

نکته بارزی که در این شبکه نیز به چشم می‌خورد آن است که الگوریتم پیشنهادی مبتنی بر eDLA به دلیل جست و جو در فضای جایگشت‌ها امتیاز بهتر و زمان کمتری دارد. اما به نظر می‌رسد ساختار به دست آمده از روش مبتنی بر eDLA در مقایسه با دیگر روش‌ها دارای ساختار پیچیده‌تری بوده و از ساختار اصلی فاصله بیشتری دارد.

در این آزمایش علاوه بر الگوریتم‌های مذبور از الگوریتم ges نیز برای جست و جو در فضای PDAG‌ها استفاده شد. نتایج نشان داد که این الگوریتم قادر است با نمونه ۱۰۰۰۰۱ تایی مذبور کار یادگیری ساختاری شبکه بیزی را در زمانی برابر با ۲۴۲۰۰ ثانیه انجام دهد که نسبت به روش‌های جست و جوی حریصانه در فضای ساختارها حدود ۵۰٪ کاهش نشان می‌دهد اما در مقایسه با زمان اجرای الگوریتم پیشنهادی مبتنی بر eDLA بیش از ۲ برابر زمان اجرای الگوریتم پیشنهادی این مقاله است. اما ساختار پیشنهادی روش ges نسبت به سایر روش‌ها هم امتیاز بیشتری را کسب می‌کند  $10^{+0.85} \times 10^{-1}$  و هم ساختار حاصل بسیار به ساختار شبکه اصلی نزدیک است.

- و مهندسی کامپیوتر ایران، ب- مهندسی کامپیوتر، دوره ۱۲، شماره ۲،  
ص. ۱۱۹-۱۲۶، زمستان ۱۳۹۳.
- [36] M. R. Mollakhalil Meybodi and M. R. Meybodi, *Extended Distributed Learning Automata: A New Method for Solving Stochastic Graph Optimization Problems*, arXiv Prepr. arXiv1308.2772, Aug. 2013.
- [37] M. R. Mollakhalil Meybodi and M. R. Meybodi, "Extended distributed learning automata: an automata-based framework for solving stochastic graph optimization problems," *Appl. Intell.*, vol. 41, no. 2, pp. 923-940, 2014.
- [38] M. R. Mollakhalil Meybodi and M. R. Meybodi, "Solving stochastic permutation optimization using monte carlo sampling: a learning automata based framework," *Submitt. to Appl. Soft Comput.*, 2013.
- [۳۹] م. ملکلی میبدی و م. میبدی، حل مسئله درخت پوشایی کمینه تصادفی از طریق بهینه‌سازی جایگشت: یک رهیافت مبتنی بر آتوماتا یادگیر توزیع شده. ۱۳۹۵.
- [40] A. Rezvanian and M. R. Meybodi, "A new learning automata-based sampling algorithm for social networks," *Int. J. Commun. Syst.*, p. n/a–n/a, 2015.
- [۴۱] م. ملکلی میبدی و م. میبدی، "یک چارچوب مبتنی بر آتوماتا یادگیر توزیع شده توسعه یافته برای حل مسئله یافتن زیرگراف بهینه تصادفی," نشریه مهندسی برق و مهندسی کامپیوتر ایران، ب- مهندسی کامپیوتر، دوره ۱۲، شماره ۲، ص. ۸۵-۹۷، زمستان ۱۳۹۳.
- [42] M. Thathachar and K. Ramakrishnan, "A hierarchical system of learning automata," *IEEE Trans. Syst. Man. Cybern.*, vol. 11, no. 3, pp. 236-241, 1981.
- [43] H. Beigy and M. R. Meybodi, "Utilizing distributed learning automata to solve stochastic shortest path problems," *Int. J. Uncertainty, Fuzziness Knowledge-Based Syst.*, vol. 14, no. 5, pp. 591-615, Oct. 2006.
- [44] F. Norman, "On the linear model with two absorbing," *J. Math. Psychol.*, vol. 5, pp. 225-241, 1968.
- [45] S. Lakshmivarahan and M. Thathachar, "Bounds on the convergence probabilities of learning automata," *IEEE Trans. Syst. Man, Cybern.-Part A Syst. Humans*, vol. 6, no. 11, pp. 756-763, 1976.
- [46] V. Lepar and P. P. Shenoy, "A comparison of lauritzen-spiegelhalter, hugin, and shenoy-shafer architectures for computing marginals of probability distributions," in *Proc. of the 14th Conf. on Uncertainty in Artificial Intelligence, UAI'98*, pp. 328-337, 1998.
- [47] R. M. C. G. F. C. Ingo A. Beinlich Henri Jacques Suermontd, "The ALARM Monitoring System: A Case Study with Two Probabilistic Inference Techniques for Belief Networks," 1989.

**محمد رضا ملکلی میبدی** تحصیلات خود را در مقاطع کارشناسی و کارشناسی ارشد و دکتری کامپیوتر به ترتیب در سال های ۱۳۸۰ و ۱۳۸۲ و ۱۳۹۳ و در دانشگاه های شهید بهشتی تهران، صنعتی امیرکبیر و دانشگاه آزاد اسلامی واحد علوم و تحقیقات به پایان رسانده است و هم‌اکنون استادیار گروه مهندسی کامپیوتر دانشگاه آزاد اسلامی واحد میبد است. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: شبکه‌های کامپیوتری و نرم‌افزاری، محاسبات نرم و کاربردهای آن.

**محمد رضا میبدی** تحصیلات خود را در مقاطع کارشناسی و کارشناسی ارشد اقتصاد به ترتیب در سال های ۱۳۵۲ و ۱۳۵۶ از دانشگاه شهید بهشتی و در مقاطع کارشناسی ارشد و دکتری علوم کامپیوتر به ترتیب در سال های ۱۳۵۹ و ۱۳۶۲ از دانشگاه اوکلاهوما آمریکا به پایان رسانده است و هم‌اکنون استاد دانشکده مهندسی کامپیوتر دانشگاه صنعتی امیرکبیر می‌باشد. نامبرده قبل از پیوستش به دانشگاه صنعتی امیرکبیر در سال های ۱۳۶۲ تا ۱۳۶۴ استادیار دانشگاه پیشیگان غربی و در سال های ۱۳۶۴ تا ۱۳۷۰ دانشیار دانشگاه اوهایو در ایالات متحده آمریکا بوده است. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: الگوریتم‌های موازی، پردازش موازی، محاسبات نرم و کاربردهای آن، شبکه‌های کامپیوتری و مهندسی نرم‌افزار.

- [12] K. Shibata, H. Nakano, and A. Miyauchi, "A learning method for dynamic Bayesian network structures using a multi-objective particle swarm optimizer," *Artif. Life Robot.*, vol. 16, no. 3, pp. 329-332, Dec. 2011.
- [13] K. Salama and A. Freitas, "ABC-miner: an ant-based Bayesian classification algorithm," *Swarm Intell.*, 2012.
- [14] T. Wang and J. Yang, "A heuristic method for learning Bayesian networks using discrete particle swarm optimization," *Knowl. Inf. Syst.*, vol. 24, no. 2, pp. 269-281, Aug. 2009.
- [15] P. C. Pinto, A. Nagele, M. Dejori, T. A. Runkler, and J. M. C. Sousa, "Using a local discovery ant algorithm for Bayesian network structure learning," *IEEE Trans. Evol. Comput.*, vol. 13, no. 4, pp. 767-779, Aug. 2009.
- [16] R. Daly, Q. Shen, and S. Aitken, "Using ant colony optimization in learning Bayesian network equivalence classes," in *Proc. UKCI*, pp. 111-118, 2006.
- [17] T. Brouard, A. Delaplace, and H. Cardot, *Evolutionary Methods for Learning Bayesian Network Structures*, 2008.
- [18] J. Lee, W. Chung, E. Kim, and S. Kim, "A new genetic approach for structure learning of Bayesian networks: matrix genetic algorithm," *Int. J. Control. Autom. Syst.*, vol. 8, no. 2, pp. 398-407, Apr. 2010.
- [19] L. de Campos and J. Huete, "On the use of independence relationships for learning simplified belief networks," *Int. J. Intell. Syst.*, vol. 12, no. 7, pp. 495-522, 1997.
- [20] S. Acid and L. M. de Campos, "A hybrid methodology for learning belief networks: BENEDICT," *Int. J. Approx. Reason.*, vol. 27, no. 3, pp. 235-262, Sep. 2001.
- [21] R. Blanco, I. Inza, and P. Larrañaga, "Learning Bayesian networks in the space of structures by estimation of distribution algorithms," *Int. J. Intell. Syst.*, vol. 18, no. 2, pp. 205-220, Feb. 2003.
- [22] M. Teyssier and D. Koller, "Ordering-Based Search: A Simple and Effective Algorithm for Learning Bayesian Networks," arXiv:1207.1429, 2012.
- [23] W. Hsu, H. Guo, B. Perry, and J. Stilson, "A Permutation Genetic Algorithm for Variable Ordering in Learning Bayesian Networks from Data," GECCO, 2002.
- [24] P. Larrañaga, C. M. H. Kuijpers, R. H. Murga, and Y. Yurramendi, "Learning Bayesian network structures by searching for the best ordering with genetic algorithms," *IEEE Trans. Syst. Man, Cybern.-Part A Syst. Humans*, vol. 26, no. 4, pp. 487-493, Jul. 1996.
- [25] N. Friedman, M. Linial, I. Nachman, and D. Pe'er, "Using Bayesian networks to analyze expression data," *J. Comput. Biol.*, vol. 7, no. 3-4, pp. 601-620, Jan. 2000.
- [26] T. Silander and P. Myllymaki, *A Simple Approach for Finding the Globally Optimal Bayesian Network Structure*, arXiv Prepr. arXiv1206.6875, Jun. 2012.
- [27] O. Francois, *BNT Structure Learning Package: Documentation and Experiments*, 2004.
- [28] D. Margaritis, *Learning Bayesian Network Model Structure from Data*, Ph.D. Thesis, School of Computer Science, Carnegie Mellon University, 2003.
- [29] K. P. Murphy, *Machine Learning: A Probabilistic Perspective (Adaptive Computation and Machine Learning Series)*, the MIT Press, 2012.
- [30] P. Munteanu and M. Bendou, "The EQ framework for learning equivalence classes of Bayesian networks," in *Proc. 2001 IEEE Int. Conf. on Data Mining, ICDM'01*, pp. 417-424, San Jose, CA, USA, 2001.
- [31] D. Chickering, "Learning equivalence classes of Bayesian-network structures," *J. Mach. Learn. Res.*, vol. 2, no. 3, pp. 445-498, 2002.
- [32] R. Castelo and T. Kocka, "On inclusion-driven learning of Bayesian networks," *J. Mach. Learn. Res.*, vol. 4, pp. 527-574, 2003.
- [33] D. M. Chickering, "Optimal structure identification with greedy search," *J. Mach. Learn. Res.*, vol. 3, pp. 507-554, 2003.
- [34] M. A. Thathachar and B. Harita, "Learning automata with changing number of actions," *IEEE Trans. Syst. Man, Cybern.-Part A Syst. Humans*, vol. 17, no. 6, pp. 1095-1100, Nov./Dec. 1987.
- [۳۵] م. ملکلی میبدی و م. میبدی، "یک الگوریتم جدید مبتنی بر آتوماتا یادگیر توزیع شده توسعه یافته برای یادگیری پارامتری شبکه بیزی،" نشریه مهندسی برق